



TUGAS AKHIR - SS141501

**PERAMALAN KANDUNGAN *PARTICULATE  
MATTER* (PM10) DALAM UDARA AMBIEN  
KOTA SURABAYA MENGGUNAKAN *DOUBLE  
SEASONAL* ARIMA (DSARIMA)**

BERNADETA CHRISDAYANTI  
NRP 1311 100 005

Dosen Pembimbing  
Dr. Drs. Agus Suharsono, M.S

Program Studi S1 Statistika  
Fakultas Matematika dan Ilmu Pengetahuan Alam  
Institut Teknologi Sepuluh Nopember  
Surabaya 2015



**TUGAS AKHIR - SS141501**

**PERAMALAN KANDUNGAN *PARTICULATE MATTER* (PM10) DALAM UDARA AMBIEN KOTA SURABAYA MENGGUNAKAN *DOUBLE SEASONAL* ARIMA (DSARIMA)**

**BERNADETA CHRISDAYANTI**  
NRP 1311 100 005

Dosen Pembimbing  
Dr. Drs. Agus Suharsono, M.S

Program Studi S1 Statistika  
Fakultas Matematika dan Ilmu Pengetahuan Alam  
Institut Teknologi Sepuluh Nopember  
Surabaya 2015



**FINAL PROJECT - SS141051**

**FORECASTING OF PARTICULATE MATTER  
(PM<sub>10</sub>) ON AMBIENT AIR OF SURABAYA  
USING DOUBLE SEASONAL ARIMA (DSARIMA)**

**BERNADETA CHRISDAYANTI**  
**NRP 1311 100 005**

Supervisor  
**Dr. Drs. Agus Suharsono, M.S**

Undergraduate Programme Of Statistics  
Faculty of Mathematics and Natural Sciences  
Institut Teknologi Sepuluh Nopember  
Surabaya 2015

**LEMBAR PENGESAHAN**

**PERAMALAN KANDUNGAN *PARTICULATE MATTER* (PM10) DALAM UDARA AMBIEN KOTA SURABAYA MENGGUNAKAN *DOUBLE SEASONAL* ARIMA (DSARIMA)**

**TUGAS AKHIR**

Diajukan Untuk Memenuhi Salah Satu Syarat Kelulusan  
Program Studi S-1 Jurusan Statistika  
Fakultas Matematika dan Ilmu Pengetahuan Alam  
Institut Teknologi Sepuluh Nopember

Oleh :

**BERNADETA CHRISDAYANTI**  
**NRP. 1311 100 005**

Disetujui oleh Pembimbing Tugas Akhir :

**Dr. Drs. Agus Suharsono, M.S**  
**NIP. 19580823 198403 1 003**

()

Mengetahui  
Ketua Jurusan Statistika FMIPA-ITS

  
**Dr. Muhammad Mashuri, MT**  
**NIP. 19620408 198701 1 001**

**SURABAYA, JULI 2015**

# **PERAMALAN KANDUNGAN *PARTICULATE MATTER* (PM10) DALAM UDARA AMBIEN KOTA SURABAYA MENGGUNAKAN *DOUBLE SEASONAL ARIMA* (DSARIMA)**

**Nama Mahasiswa : Bernadeta Chrisdayanti**  
**NRP : 1311 100 005**  
**Jurusan : Statistika FMIPA-ITS**  
**Dosen Pembimbing : Dr. Drs. Agus Suharsono, M.S**

## **ABSTRAK**

*Surabaya merupakan salah satu kota besar di Indonesia yang memiliki jumlah penduduk yang padat dan diiringi oleh banyaknya jumlah kendaraan bermotor. Alat transportasi pribadi sangat mempermudah akomodasi, namun dapat menimbulkan polusi udara. Polusi udara dipantau berdasarkan 5 parameter, salah satunya PM10. PM10 merupakan parameter untuk menyatakan banyaknya kandungan debu dalam udara dan kandungannya paling banyak dalam udara ambien Kota Surabaya pada tahun 2014. Salah satu faktor yang mempengaruhi kandungan PM10 adalah asap kendaraan bermotor. Dampak dari tingginya kandungan PM10 akan langsung dirasakan oleh makhluk hidup. Oleh karena itu, kandungan PM10 perlu dikontrol setiap hari, bahkan setiap jam. Pengontrolan per jam dilakukan karena kandungan PM10 akan sangat tinggi pada jam 10.00 hingga 13.00, dimana nilai ISPUnya dapat melebihi batas udara dinyatakan sehat. Proses pengontrolan untuk beberapa jam dan hari berikutnya dapat dilakukan dengan menggunakan metode time series ARIMA. Metode ini dipilih karena kandungan PM10 dipengaruhi oleh waktu-waktu sebelumnya dan skala waktu yang digunakan konstan yaitu per jam. Stasiun pengamatan yang akan digunakan adalah SUF 6 dan SUF 7. Pemilihan model terbaik didasarkan pada kriteria out sample Root Mean Square Error (RMSE). Model terbaik yang dapat digunakan untuk mengontrol kandungan PM10 per jam di SUF 6 adalah ARIMA  $([1,2,4,7,8,9,10,12,16,17,18],1,0)(1,1,1)^{24}(0,1,1)^{168}$  dan ARIMA  $([1,2,4,5,7,8,10,11,12,13,15,16,18,19,20],1,0)(1,1,1)^{24}(0,1,1)^{168}$ .*

**Kata kunci :** ARIMA, Peramalan, PM10, RMSE, Udara Ambien.

# **FORECASTING OF PARTICULATE MATTER (PM10) ON AMBIENT AIR OF SURABAYA USING DOUBLE SEASONAL ARIMA (DSARIMA)**

**Name of Student** : Bernadeta Chrisdayanti  
**NRP** : 1311 100 005  
**Department** : Statistics FMIPA-ITS  
**Supervisor** : Dr. Drs. Agus Suharsono, M.S

## **ABSTRACT**

*Surabaya is one of the major cities in Indonesia, which has dense population and accompanied by large number of vehicles for transportation. Personal transportation not only simplify the accommodation, but also can cause air pollution. Air pollution is monitored based on 5 parameters, one of them is PM10. PM10 is parameter to declare the amount of dust content in the air and its contents is the highest on ambient air of Surabaya in 2014. One of the factors that affect the content of PM10 is smoke from motor vehicles. The impact of the high content of PM10 will be directly felt the living creatures. Therefore, PM10 should be controlled every day, even every hour. Controlling hourly is done because the content will be very high at 10:00 until 13:00, which may exceed the limit ISPU value of healthy air. Controlling for the next hours and days using time series ARIMA method. This method is chosen because the content of PM10 is influenced by other time and time scales are constant used by the hour, so it can be satisfied the method rules of time series. Observation stations that will be used is SUF 6 and SUF 7. Criteria selection are based on the best model out sample Root Mean Square Error (RMSE). The best model that can be used to control the content of PM10 per hour in SUF 6 are ARIMA  $([1,2,4,7,8,9,10,12,16,17,18],1,0)(1,1,1)^{24}(0,1,1)^{168}$  and ARIMA  $([1,2,4,5,7,8,10,11,12,13,15,16,18,19,20],1,0)(1,1,1)^{24}(0,1,1)^{168}$ .*

**Keywords** : Ambient Air, ARIMA, Forecasting, PM10, RMSE..

## KATA PENGANTAR

Puji syukur kepada Tuhan Yesus atas hikmat yang diberikan kepada penulis, sehingga penulis dapat menyelesaikan laporan Tugas Akhir yang berjudul **“Peramalan Kandungan *Particulate Matter* (PM10) Dalam Udara Ambien Kota Surabaya Menggunakan *Double Seasonal ARIMA* (DSARIMA)”** dengan baik. terselesaikannya Tugas Akhir ini tidak terlepas dari dukungan berbagai pihak yang telah memberikan bimbingan dan bantuan pada penulis. Untuk itu, pada kesempatan ini penulis mengucapkan terima kasih sedalam-dalamnya kepada :

1. Bapak Dr. Drs. Agus Suharsono, M.S selaku dosen pembimbing atas segala bimbingan, saran, semangat, kesabaran dan waktu yang diberikan kepada penulis hingga laporan Tugas Akhir ini selesai.
2. Bapak Dr. Suhartono, S.Si, M.Sc dan Ibu Dra. Destri Susilaningrum, M.Si selaku dosen penguji atas kritik dan saran demi perbaikan Tugas Akhir ini.
3. Bapak Dr. Muhammad Mashuri, M.T selaku Ketua Jurusan Statistika ITS dan Ibu Dra. Lucia Aridinanti, M.S selaku Koordinator Program Studi S1 Jurusan Statistika ITS yang telah memfasilitasi untuk kelancaran penyelesaian Tugas Akhir ini.
4. Bapak Prof. Dr. Drs. I Nyoman Budiantara, S.Si selaku dosen wali yang telah membimbing penulis sejak awal masuk kuliah hingga penulis telah menyelesaikan studinya di jenjang S1 ini.
5. Seluruh dosen dan karyawan jurusan Statistika ITS, atas ilmu yang diberikan selama penulis berada di bangku kuliah.
6. Orangtua tercinta, Bapak Warni dan Ibu Gagik Pudjiastuti, yang selalu mendoakan penulis, serta Mas Louis Gandhi Prabowo, kakak laki-laki penulis, yang selalu memberi motivasi dan inspirasi kepada penulis.
7. Bestpren (Chusnul, Kartika, Ayyak, Dova), kontrakan galau (Vini, Ninis, Reta, Kiki Ferawati, Indah Tri), asrama galau

(Indah Kurnia, Charisma, Indana, Ratu) dan teman seperjuangan dari Magetan (Argita) atas dukungan dan kebersamaan selama ini.

8. Teman-teman laboratorium ekonomi bisnis: Purwa, Yulia, Zulfikar, Aulia Masyita, Nunun, Brian, Indah Tri atas ilmu yang dibagi selama pengerjaan Tugas Akhir ini.
9. BPH Persekutuan Mahasiswa Kristen (PMK) ITS 2014/2015: Dharma, Elok, Resti, Irin, Yosia, Yemima, Bergas, Johan, Wim atas kebersamaan dan persekutuan yang membangun rohani penulis.
10. Kelompok Kecil, Iko dan Mbak Sevy, atas dukungan dan kebersamaan selama ini.
11. Sigma 22 yang telah memberikan kebersamaan selama ini.

Penulis merasa masih banyak kekurangan dari segi teknis penulisan maupun materi dari Tugas Akhir ini. Oleh karena itu, kritik dan saran dari semua pihak sangat diharapkan untuk perbaikan penelitian-penelitian selanjutnya. Semoga Tugas Akhir ini dapat memberikan banyak manfaat bagi semua pihak.

Surabaya, Juli 2015

Penulis



## DAFTAR ISI

<b>HALAMAN JUDUL.....</b>	<b>i</b>
<b>LEMBAR PENGESAHAN.....</b>	<b>v</b>
<b>ABSTRAK.....</b>	<b>vii</b>
<b>ABSTRACT .....</b>	<b>ix</b>
<b>KATA PENGANTAR .....</b>	<b>xi</b>
<b>DAFTAR ISI.....</b>	<b>xiii</b>
<b>DAFTAR TABEL.....</b>	<b>xv</b>
<b>DAFTAR GAMBAR.....</b>	<b>xvii</b>
<b>DAFTAR LAMPIRAN .....</b>	<b>xxi</b>
<b>BAB I PENDAHULUAN .....</b>	<b>1</b>
1.1 Latar Belakang.....	1
1.2 Rumusan Masalah .....	3
1.3 Tujuan.....	4
1.4 Manfaat.....	4
1.5 Batasan Masalah.....	4
<b>BAB II TINJAUAN PUSTAKA.....</b>	<b>5</b>
2.1 Kualitas Udara Ambien .....	5
2.2 Jaringan Pemantauan Kualitas Udara Ambien .....	6
2.3 Statistika Deskriptif.....	8
2.3.1 Rata-rata .....	8
2.3.2 Standar Deviasi .....	9
2.3.3 Plot <i>Time Series</i> .....	9
2.3.4 <i>Boxplot</i> .....	10
2.4 Analisis <i>Time Series</i> .....	10
2.5 Stasioneritas.....	11
2.6 <i>Autocorrelation Function</i> (ACF).....	12
2.7 <i>Partial Autocorrelation Function</i> (PACF) .....	13
2.8 <i>Autoregressive Integrated Moving Average</i> (ARIMA) .....	13
2.9 <i>Seasonal ARIMA</i> (SARIMA) .....	14
2.10 <i>Double Seasonal ARIMA</i> (DSARIMA).....	14
2.11 Model <i>Subset</i> , <i>Multiplicative</i> dan <i>Additive</i> .....	15
2.11.1 Model <i>Subset</i> .....	15

2.11.2 Model <i>Multiplicative</i> .....	15
2.11.3 Model <i>Additive</i> .....	16
2.12 Prosedur Box-Jenkins .....	17
2.12.1 Tahap Identifikasi .....	17
2.12.2 Tahap Estimasi Parameter .....	18
2.12.3 Tahap Cek Diagnosa .....	20
2.12.4 Tahap Peramalan .....	20
2.13 Pemilihan Keباikan Model .....	21
<b>BAB III METODOLOGI PENELITIAN.....</b>	<b>23</b>
3.1 Sumber Data .....	23
3.2 Lokasi Penelitian .....	24
3.3 Variabel Penelitian .....	24
3.4 Metode Analisis .....	26
3.5 Langkah Analisis .....	26
3.6 Diagram Alir Penelitian .....	28
<b>BAB IV HASIL ANALISIS DAN PEMBAHASAN .....</b>	<b>29</b>
4.1 Statistika Deskriptif .....	29
4.2 Pemodelan Menggunakan <i>Double Seasonal</i> ARIMA .....	41
4.3 Statistika Deskriptif <i>Peak</i> Kandungan PM10 .....	54
4.4 Pemodelan ARIMA pada <i>Peak</i> Kandungan PM10 ....	56
<b>BAB V KESIMPULAN DAN SARAN .....</b>	<b>65</b>
5.1 Kesimpulan .....	65
5.2 Saran .....	66
<b>DAFTAR PUSTAKA .....</b>	<b>67</b>
<b>LAMPIRAN .....</b>	<b>71</b>

## DAFTAR ISI

<b>HALAMAN JUDUL.....</b>	<b>i</b>
<b>LEMBAR PENGESAHAN.....</b>	<b>v</b>
<b>ABSTRAK.....</b>	<b>vii</b>
<b>ABSTRACT .....</b>	<b>ix</b>
<b>KATA PENGANTAR .....</b>	<b>xi</b>
<b>DAFTAR ISI.....</b>	<b>xiii</b>
<b>DAFTAR TABEL.....</b>	<b>xv</b>
<b>DAFTAR GAMBAR.....</b>	<b>xvii</b>
<b>DAFTAR LAMPIRAN .....</b>	<b>xxi</b>
<b>BAB I PENDAHULUAN .....</b>	<b>1</b>
1.1 Latar Belakang.....	1
1.2 Rumusan Masalah .....	3
1.3 Tujuan.....	4
1.4 Manfaat.....	4
1.5 Batasan Masalah.....	4
<b>BAB II TINJAUAN PUSTAKA.....</b>	<b>5</b>
2.1 Kualitas Udara Ambien .....	5
2.2 Jaringan Pemantauan Kualitas Udara Ambien .....	6
2.3 Statistika Deskriptif.....	8
2.3.1 Rata-rata .....	8
2.3.2 Standar Deviasi .....	9
2.3.3 Plot <i>Time Series</i> .....	9
2.3.4 <i>Boxplot</i> .....	10
2.4 Analisis <i>Time Series</i> .....	10
2.5 Stasioneritas.....	11
2.6 <i>Autocorrelation Function</i> (ACF).....	12
2.7 <i>Partial Autocorrelation Function</i> (PACF) .....	13
2.8 <i>Autoregressive Integrated Moving Average</i> (ARIMA) .....	13
2.9 <i>Seasonal ARIMA</i> (SARIMA) .....	14
2.10 <i>Double Seasonal ARIMA</i> (DSARIMA).....	14
2.11 Model <i>Subset</i> , <i>Multiplicative</i> dan <i>Additive</i> .....	15
2.11.1 Model <i>Subset</i> .....	15

2.11.2 Model <i>Multiplicative</i> .....	15
2.11.3 Model <i>Additive</i> .....	16
2.12 Prosedur Box-Jenkins .....	17
2.12.1 Tahap Identifikasi .....	17
2.12.2 Tahap Estimasi Parameter .....	18
2.12.3 Tahap Cek Diagnosa .....	20
2.12.4 Tahap Peramalan .....	20
2.13 Pemilihan Keباikan Model .....	21
<b>BAB III METODOLOGI PENELITIAN.....</b>	<b>23</b>
3.1 Sumber Data .....	23
3.2 Lokasi Penelitian .....	24
3.3 Variabel Penelitian .....	24
3.4 Metode Analisis .....	26
3.5 Langkah Analisis .....	26
3.6 Diagram Alir Penelitian .....	28
<b>BAB IV HASIL ANALISIS DAN PEMBAHASAN .....</b>	<b>29</b>
4.1 Statistika Deskriptif .....	29
4.2 Pemodelan Menggunakan <i>Double Seasonal</i> ARIMA .....	41
4.3 Statistika Deskriptif <i>Peak</i> Kandungan PM10 .....	54
4.4 Pemodelan ARIMA pada <i>Peak</i> Kandungan PM10 ....	56
<b>BAB V KESIMPULAN DAN SARAN .....</b>	<b>65</b>
5.1 Kesimpulan .....	65
5.2 Saran .....	66
<b>DAFTAR PUSTAKA .....</b>	<b>67</b>
<b>LAMPIRAN .....</b>	<b>71</b>

## DAFTAR GAMBAR

	Halaman
Gambar 2.1	Contoh Plot <i>Time Series</i> ..... 10
Gambar 3.1	Stasiun Pemantauan Kualitas Udara ..... 24
Gambar 3.2	Peta Kota Surabaya..... 25
Gambar 3.3	Diagram Alir Penelitian..... 27
Gambar 4.1	Plot <i>Time Series</i> Kandungan PM10..... 30
Gambar 4.2	Plot <i>Time Series</i> Kandungan PM10 Per Jam di SUF 6 ..... 32
Gambar 4.3	Plot <i>Time Series</i> Kandungan PM10 Per Jam di SUF 7 ..... 33
Gambar 4.4	Plot Rata-rata Kandungan PM10 Per Jam Per Hari di SUF 6 ..... 34
Gambar 4.5	Plot Standar Deviasi Kandungan PM10 Per Jam Per Hari di SUF 6..... 34
Gambar 4.6	Plot Rata-rata Kandungan PM10 Per Jam Per Hari di SUF 7 ..... 35
Gambar 4.7	Plot Standar Deviasi Kandungan PM10 Per Jam Per Hari di SUF 7..... 35
Gambar 4.8	Plot Rata-rata Kandungan PM10 Per Jam Per Bulan di SUF 6..... 37
Gambar 4.9	Plot Rata-rata Kandungan PM10 Per Jam Per Bulan di SUF 7..... 37
Gambar 4.10	<i>Box Plot</i> Kandungan PM10 Per Jam di SUF 6..... 38
Gambar 4.11	<i>Box Plot</i> Kandungan PM10 Per Jam di SUF 7..... 38
Gambar 4.12	Plot <i>Time Series</i> Kandungan PM10 Per Hari di SUF 6..... 39
Gambar 4.13	Plot <i>Time Series</i> Kandungan PM10 Per Hari di SUF 7..... 40
Gambar 4.14	Plot Varians Kandungan PM10 Per Hari di SUF 6 dan SUF 7..... 40

Gambar 4.15	Plot Rata-rata Kandungan PM10 Per Hari di SUF 6 dan SUF 7 .....	41
Gambar 4.16	Plot ACF Data Kandungan PM10 di SUF 6 .....	42
Gambar 4.17	Plot PACF Data Kandungan PM10 di SUF 6 .....	42
Gambar 4.18	Plot ACF Data Kandungan PM10 di SUF 7 .....	43
Gambar 4.19	Plot PACF Data Kandungan PM10 di SUF 7 .....	43
Gambar 4.20	Plot ACF Data Kandungan PM10 di SUF 6 Setelah <i>Differencing</i> Lag 1, 24, dan 168.....	44
Gambar 4.21	Plot PACF Data Kandungan PM10 di SUF 6 Setelah <i>Differencing</i> Lag 1, 24, dan 168.....	44
Gambar 4.22	Plot ACF Data Kandungan PM10 di SUF 7 Setelah <i>Differencing</i> Lag 1, 24, dan 168.....	45
Gambar 4.23	Plot PACF Data Kandungan PM10 di SUF 7 Setelah <i>Differencing</i> Lag 1, 24, dan 168.....	45
Gambar 4.24	Plot ACF Residual (a) Model 1 dan (b) Model 2 DSARIMA untuk SUF 6.....	49
Gambar 4.25	Plot ACF Residual (a) Model 1 dan (b) Model 2 DSARIMA untuk SUF 7.....	49
Gambar 4.26	Hasil Ramalan Data <i>Out Sample</i> Kandungan PM10 di (a) SUF 6 dan (b) SUF 7 .....	51
Gambar 4.27	Rata-rata Hasil Ramalan Data <i>Out Sample</i> Kandungan PM10 di (a) SUF 6 dan (b) SUF 7.....	52
Gambar 4.28	Plot <i>Time Series</i> antara Data Aktual dengan Hasil Ramalan Kandungan PM10 di SUF 6.....	52

Gambar 4.29	Plot <i>Time Series</i> antara Data Aktual dengan Hasil Ramalan Kandungan PM10 di SUF 7.....	53
Gambar 4.30	<i>Iterative RMSE Out Sample</i> .....	53
Gambar 4.31	Plot <i>Time Series Peak</i> Kandungan PM10 di SUF 6.....	55
Gambar 4.32	Plot <i>Time Series Peak</i> Kandungan PM10 di SUF 7.....	55
Gambar 4.33	Plot ACF <i>Peak</i> Kandungan PM10 di SUF 6 pukul (a)10.00, (b)11.00, (c)12.00 dan (d)13.00.....	57
Gambar 4.34	Plot ACF <i>Peak</i> Kandungan PM10 di SUF 7 pukul (a)10.00, (b)11.00, (c)12.00 dan (d)13.00.....	57
Gambar 4.35	Plot ACF <i>Peak</i> Kandungan PM10 di SUF 6 pukul (a)10.00, (b)11.00, (c)12.00 dan (d)13.00 Setelah <i>Differencing</i> 7 .....	58
Gambar 4.36	Plot PACF <i>Peak</i> Kandungan PM10 di SUF 6 pukul (a)10.00, (b)11.00, (c)12.00 dan (d)13.00 Setelah <i>Differencing</i> 7 .....	58
Gambar 4.37	Plot ACF <i>Peak</i> Kandungan PM10 di SUF 7 pukul (a)10.00, (b)11.00, (c)12.00 dan (d)13.00 Setelah <i>Differencing</i> 7 .....	59
Gambar 4.38	Plot PACF <i>Peak</i> Kandungan PM10 di SUF 7 pukul (a)10.00, (b)11.00, (c)12.00 dan (d)13.00 Setelah <i>Differencing</i> 7 .....	59
Gambar 4.39	Plot ACF Residual Model <i>Peak</i> Kandungan PM10 di SUF 6 pukul (a)10.00, (b)11.00, (c)12.00 dan (d)13.00.....	62
Gambar 4.40	Plot ACF Residual Model <i>Peak</i> Kandungan PM10 di SUF 7 pukul (a)10.00, (b)11.00, (c)12.00 dan (d)13.00.....	62

## DAFTAR LAMPIRAN

	Halaman
Lampiran 1 Data Kandungan PM <sub>10</sub> di SUF 6 dan SUF 7 Tahun 2014.....	71
Lampiran 2 Syntax Pemodelan 1 DSARIMA Data Kandungan PM <sub>10</sub> di SUF 6 dengan SAS .....	72
Lampiran 3 Syntax Pemodelan 2 ARIMA Data Kandungan PM <sub>10</sub> di SUF 6 dengan SAS .....	73
Lampiran 4 Syntax Pemodelan 1 DSARIMA Data Kandungan PM <sub>10</sub> di SUF 7 dengan SAS .....	74
Lampiran 5 Syntax Pemodelan 2 DSARIMA Data Kandungan PM <sub>10</sub> di SUF 7 dengan SAS .....	75
Lampiran 6 Syntax Pemodelan SARIMA Data Kandungan PM <sub>10</sub> di SUF 6 jam 10.00 dengan SAS .....	76
Lampiran 7 Syntax Pemodelan SARIMA Data Kandungan PM <sub>10</sub> di SUF 6 jam 11.00 dengan SAS .....	77
Lampiran 8 Syntax Pemodelan SARIMA Data Kandungan PM <sub>10</sub> di SUF 6 jam 12.00 dengan SAS .....	78
Lampiran 9 Syntax Pemodelan SARIMA Data Kandungan PM <sub>10</sub> di SUF 6 jam 13.00 dengan SAS .....	79
Lampiran 10 Syntax Pemodelan SARIMA Data Kandungan PM <sub>10</sub> di SUF 7 jam 10.00 dengan SAS .....	80
Lampiran 11 Syntax Pemodelan SARIMA Data Kandungan PM <sub>10</sub> di SUF 7 jam 11.00 dengan SAS .....	81
Lampiran 12 Syntax Pemodelan SARIMA Data Kandungan PM <sub>10</sub> di SUF 7 jam 12.00 dengan SAS .....	82



Lampiran 13	Syntax Pemodelan SARIMA Data Kandungan PM <sub>10</sub> di SUF 7 jam 13.00 dengan SAS .....	83
Lampiran 14	Output SAS Pemodelan 1 DSARIMA Data Kandungan PM <sub>10</sub> di SUF 6.....	84
Lampiran 15	Output SAS Pemodelan 2 DSARIMA Data Kandungan PM <sub>10</sub> di SUF 6.....	85
Lampiran 16	Output SAS Pemodelan 1 DSARIMA Data Kandungan PM <sub>10</sub> di SUF 7.....	86
Lampiran 17	Output SAS Pemodelan 2 DSARIMA Data Kandungan PM <sub>10</sub> di SUF 7.....	87
Lampiran 18	Output SAS Pemodelan SARIMA Data Kandungan PM <sub>10</sub> pukul 10.00 di SUF 6.....	88
Lampiran 19	Output SAS Pemodelan SARIMA Data Kandungan PM <sub>10</sub> pukul 11.00 di SUF 6.....	89
Lampiran 20	Output SAS Pemodelan SARIMA Data Kandungan PM <sub>10</sub> pukul 12.00 di SUF 6.....	90
Lampiran 21	Output SAS Pemodelan SARIMA Data Kandungan PM <sub>10</sub> pukul 13.00 di SUF 6.....	91
Lampiran 22	Output SAS Pemodelan SARIMA Data Kandungan PM <sub>10</sub> pukul 10.00 di SUF 7.....	92
Lampiran 23	Output SAS Pemodelan SARIMA Data Kandungan PM <sub>10</sub> pukul 11.00 di SUF 7.....	93
Lampiran 24	Output SAS Pemodelan SARIMA Data Kandungan PM <sub>10</sub> pukul 12.00 di SUF 7.....	94
Lampiran 25	Output SAS Pemodelan SARIMA Data Kandungan PM <sub>10</sub> pukul 13.00 di SUF 7.....	95
Lampiran 26	<i>Box Cox</i> Data Kandungan PM10 di SUF 6 Sebelum Ditransformasi .....	96
Lampiran 27	<i>Box Cox</i> Data Kandungan PM10 di SUF 7 Sebelum Ditransformasi .....	96
Lampiran 28	<i>Box Cox</i> Data Kandungan PM10 di SUF 6 Setelah Ditransformasi .....	97
Lampiran 29	<i>Box Cox</i> Data Kandungan PM10 di SUF 7 Setelah Ditransformasi .....	97

Lampiran 30	<i>Summary Table</i> Residual Model 1 Kandungan PM10 di SUF 6 .....	98
Lampiran 31	<i>Summary Table</i> Residual Model 2 Kandungan PM10 di SUF 6 .....	98
Lampiran 32	<i>Summary Table</i> Residual Model 1 Kandungan PM10 di SUF 7 .....	99
Lampiran 33	<i>Summary Table</i> Residual Model 2 Kandungan PM10 di SUF 7 .....	99
Lampiran 34	<i>Summary Table</i> Residual Model ARIMA Kandungan PM10 Pukul 10.00 di SUF 6.....	100
Lampiran 35	<i>Summary Table</i> Residual Model ARIMA Kandungan PM10 Pukul 11.00 di SUF 6.....	100
Lampiran 36	<i>Summary Table</i> Residual Model ARIMA Kandungan PM10 Pukul 12.00 di SUF 6.....	101
Lampiran 37	<i>Summary Table</i> Residual Model ARIMA Kandungan PM10 Pukul 13.00 di SUF 6.....	101
Lampiran 38	<i>Summary Table</i> Residual Model ARIMA Kandungan PM10 Pukul 10.00 di SUF 7.....	102
Lampiran 39	<i>Summary Table</i> Residual Model ARIMA Kandungan PM10 Pukul 11.00 di SUF 7.....	102
Lampiran 40	<i>Summary Table</i> Residual Model ARIMA Kandungan PM10 Pukul 12.00 di SUF 7.....	103
Lampiran 41	<i>Summary Table</i> Residual Model ARIMA Kandungan PM10 Pukul 13.00 di SUF 7.....	103
Lampiran 42	Plot <i>Time Series</i> Data Aktual dan Ramalan <i>In Sample</i> dan <i>Out Sample</i> Pukul 10.00 di SUF 6 .....	104
Lampiran 43	Plot <i>Time Series</i> Data Aktual dan Ramalan <i>In Sample</i> dan <i>Out Sample</i> Pukul 11.00 di SUF 6 .....	104
Lampiran 44	Plot <i>Time Series</i> Data Aktual dan Ramalan <i>In Sample</i> dan <i>Out Sample</i> Pukul 12.00 di SUF 6 .....	105

Lampiran 45	Plot <i>Time Series</i> Data Aktual dan Ramalan <i>In Sample</i> dan <i>Out Sample</i> Pukul 13.00 di SUF 6 .....	105
Lampiran 46	Plot <i>Time Series</i> Data Aktual dan Ramalan <i>In Sample</i> dan <i>Out Sample</i> Pukul 10.00 di SUF 7 .....	106
Lampiran 47	Plot <i>Time Series</i> Data Aktual dan Ramalan <i>In Sample</i> dan <i>Out Sample</i> Pukul 11.00 di SUF 7 .....	106
Lampiran 48	Plot <i>Time Series</i> Data Aktual dan Ramalan <i>In Sample</i> dan <i>Out Sample</i> Pukul 12.00 di SUF 7 .....	107
Lampiran 49	Plot <i>Time Series</i> Data Aktual dan Ramalan <i>In Sample</i> dan <i>Out Sample</i> Pukul 13.00 di SUF 7 .....	107

# **BAB I**

## **PENDAHULUAN**

### **1.1 Latar Belakang**

Indonesia merupakan negara kepulauan yang terdiri atas lima pulau besar dan ribuan pulau kecil. Salah satu pulau besarnya adalah Pulau Jawa, pulau terpadat di Indonesia. Jawa Timur sebagai salah satu provinsi yang terletak di Pulau Jawa mengakibatkan provinsi ini memiliki jumlah penduduk yang banyak. Surabaya sebagai ibukota provinsi dijadikan sebagai kota perantauan oleh sebagian penduduk Jawa Timur. Hal tersebut disebabkan oleh banyaknya perguruan tinggi dan lowongan pekerjaan yang tersedia di Surabaya. Peningkatan jumlah penduduk yang berada di Surabaya diiringi dengan peningkatan jumlah alat transportasi pribadi, seperti sepeda motor dan mobil. Kendaraan pribadi mempunyai keuntungan tersendiri bagi setiap penduduk karena mobilitas mereka akan lancar setiap harinya (Tamin, 1992). Namun, hal tersebut turut memberikan dampak pada siklus ekologis berupa polusi serta kemacetan lalu lintas. Salah satu polusi pada lingkungan hidup adalah polusi udara. Sebagai salah satu negara berkembang, maka perubahan dalam berbagai sektor, salah satunya transportasi, akan mempengaruhi kualitas udara yang ada (Bowman, 2013).

Polusi atau pencemaran udara adalah masuknya zat atau komponen lain ke dalam udara ambien yang disebabkan oleh aktivitas manusia, sehingga mutu udara ambien turun sampai ke tingkat tertentu yang menyebabkan udara ambien tidak dapat memenuhi fungsinya. Sementara udara ambien adalah udara bebas dipermukaan bumi pada lapisan troposfir yang berada di wilayah yurisdiksi Republik Indonesia yang dibutuhkan dan mempengaruhi kesehatan manusia, makhluk hidup dan unsur lingkungan hidup lainnya (PP Nomor 41 Tahun 1999).

Berdasarkan hal tersebut, maka diperlukan pemantauan dari pemerintah mengenai kualitas udara di Surabaya. Dinas yang bertugas memantau adalah Badan Lingkungan Hidup (BLH) Kota

Surabaya (Syafei, 2012). Pemantauan dilakukan dengan menggunakan alat yang dapat mengukur secara otomatis. Alat tersebut diletakkan pada 6 titik di Surabaya, dimana titik-titik tersebut mewakili 5 daerah Surabaya (BLH, 2014).

Kualitas udara dipantau berdasarkan 5 parameter, salah satunya yaitu *Particulate Matter* (PM<sub>10</sub>). Berdasarkan laporan tahunan BLH Surabaya tahun 2014, kandungan PM<sub>10</sub> pada bulan merupakan yang paling banyak dibandingkan dengan parameter yang lain. Selain itu, kandungan PM<sub>10</sub> dalam udara ambien merupakan salah satu hal yang penting (Yu, Lin, & Kuo, 2015) karena dampaknya dapat dirasakan langsung oleh masyarakat.

ARIMA merupakan salah satu metode statistik yang dapat digunakan untuk meramalkan suatu kejadian di masa depan berdasarkan data yang sudah lampau. Salah satu syarat yang harus dipenuhi adalah data bersifat *time series*. Metode ini pernah digunakan oleh Ditago (2013) untuk meramalkan konsumsi energi listrik di Jawa Timur. Kemudian, pada tahun 2014, metode ARIMA digunakan untuk meramalkan penjualan sepeda motor (Anggraeni, 2014; Badriyah, 2014; Harahap, 2014).

Data kandungan PM<sub>10</sub> bersifat *dependent*, artinya dipengaruhi oleh waktu-waktu sebelumnya, sehingga menjadi data *time series* dan dapat dianalisis menggunakan analisis *time series*. Analisis dilakukan dengan menerapkan metode Box Jenkins. Analisis statistik terhadap parameter PM<sub>10</sub> pernah dilakukan oleh Nuraini (2004) berdasarkan stasiun pemantau Taman Prestasi dengan menerapkan metode *Autoregressive Integrated Moving Average* (ARIMA). Data yang digunakan adalah data per 30 menit. Kemudian pada tahun 2011, Desvina menggunakan model *Autoregressive* (AR) untuk meramalkan PM<sub>10</sub> di Kajang Malaysia dengan data rata-rata per hari. selanjutnya pada tahun 2012, Lee menggunakan model *seasonal* ARIMA (SARIMA) untuk meramalkan kualitas udara di Malaysia dengan menggunakan data rata-rata per bulan.

Dalam kehidupan sehari-hari, seringkali ditemukan data yang memiliki pola musiman ganda. Contoh data yang memiliki

pola musiman ganda adalah data beban listrik jangka pendek dan *load demand* yang diamati dengan satuan waktu per 30 menit selama beberapa minggu. Maka musiman yang dimiliki oleh data tersebut adalah musiman harian dan musiman mingguan karena data memiliki pola yang sama setiap hari dan setiap minggu. Apabila data mengandung pola musiman ganda maka model ARIMA yang digunakan adalah *Double Seasonal* ARIMA (DSARIMA).

Penelitian yang akan dilakukan adalah meramalkan kualitas udara ambien berdasarkan parameter  $PM_{10}$  dengan 2 stasiun pemantau yang ada di Surabaya.  $PM_{10}$  dipilih karena dapat memberikan dampak secara signifikan pada makhluk hidup dan merupakan kandungan tertinggi dalam udara ambien Surabaya. Penelitian dilakukan dengan menggunakan analisis *time series* DSARIMA. Analisis tersebut dipilih karena data pengamatan, yaitu kandungan  $PM_{10}$  dalam udara ambien, memiliki skala waktu per jam dan diamati selama satu tahun. Sehingga diduga bahwa data memiliki pola musiman ganda.

## 1.2 Rumusan Masalah

Selama ini, proses pengontrolan yang dilakukan oleh Badan Lingkungan Hidup hanyalah berdasarkan statistika deskriptif, yaitu menghitung rata-rata kandungan  $PM_{10}$  per hari untuk menyatakan sehat atau tidaknya udara pada hari tersebut. Pihak setempat melakukan peramalan untuk beberapa jam kedepan dengan cara perkiraan berdasarkan kandungan  $PM_{10}$  pada jam sebelumnya. Sehingga belum pernah melakukan pengontrolan untuk jam dan hari berikutnya berdasarkan model dan metode statistik. Oleh karena itu, dalam penelitian ini digunakan pemodelan dan peramalan kandungan  $PM_{10}$  menggunakan metode statistik *time series* ARIMA dengan rumusan masalah sebagai berikut.

1. Bagaimana karakteristik kandungan  $PM_{10}$  dalam udara ambien Surabaya berdasarkan stasiun pemantau SUF 6 dan SUF 7?

2. Bagaimana model DSARIMA dengan orde yang sesuai untuk memprediksi kandungan PM10 yang dipantau berdasarkan stasiun pemantau SUF 6?
3. Bagaimana model DSARIMA dengan orde yang sesuai untuk memprediksi kandungan PM10 yang dipantau berdasarkan stasiun pemantau SUF 7?

### **1.3 Tujuan**

Tujuan yang ingin dicapai dari penelitian ini adalah sebagai berikut

1. Mengetahui karakteristik kandungan PM10 dalam udara ambien Surabaya berdasarkan stasiun pemantau SUF 6 dan SUF 7.
2. Mengetahui model DSARIMA dengan orde yang sesuai untuk memprediksi kandungan PM10 yang dipantau berdasarkan stasiun pemantau SUF 6.
3. Mengetahui model DSARIMA dengan orde yang sesuai untuk memprediksi kandungan PM10 yang dipantau berdasarkan stasiun pemantau SUF 7.

### **1.4 Manfaat**

Manfaat dari penelitian ini adalah model terbaik yang diperoleh dapat digunakan untuk mengontrol kualitas udara ambien di Surabaya, sehingga menjadi tambahan informasi untuk Pemerintah Kota Surabaya, khususnya Badan Lingkungan Hidup tentang kualitas udara ambien di Surabaya. Informasi tersebut dapat digunakan BLH untuk menjaga atau meningkatkan kualitas udara ambien di Surabaya.

### **1.5 Batasan Masalah**

Batasan masalah yang digunakan dalam penelitian ini adalah sebagai berikut :

1. Data kualitas udara merupakan hasil yang diperoleh dari alat pada stasiun pemantau yang ada di Kota Surabaya.
2. Stasiun pemantau yang digunakan dalam penelitian ini ada 2, yaitu yang berada di Kebon Bibit Wonorejo dan Halaman Kelurahan Kebonsari.

## BAB II

### TINJAUAN PUSTAKA

#### 2.1 Kualitas Udara Ambien

Kualitas udara berhubungan erat dengan pencemaran udara. Udara bebas di permukaan bumi pada lapisan troposfir disebut udara ambien. Udara ambien dibutuhkan oleh manusia. Selain itu, udara ambien juga mempengaruhi kesehatan manusia, makhluk hidup dan unsur lingkungan hidup lainnya.

Indeks Standar Pencemar Udara (ISPU) merupakan nilai yang digunakan untuk mengukur parameter kualitas udara. Indeks ini dibuat untuk menyeragamkan informasi kualitas udara ambien, sehingga mudah dimengerti oleh masyarakat. Terdapat lima parameter yang digunakan dalam ISPU. Kelima parameter tersebut meliputi

**Tabel 2.1** Parameter ISPU dan Periode Waktu Pengukuran

No.	Parameter	Periode Pengukuran Rata-Rata
1.	Partikulat (PM <sub>10</sub> )	24 jam
2.	Karbon Monoksida (CO)	8 jam
3.	Sulfur Dioksida (SO <sub>2</sub> )	24 jam
4.	Nitrogen Dioksida (NO <sub>2</sub> )	1 jam
5.	Ozon (O <sub>3</sub> )	1 jam

ISPU tidak memiliki satuan yang menggambarkan kondisi kualitas udara ambien di lokasi dan waktu tertentu, tetapi didasarkan pada dampak yang berpengaruh pada kesehatan manusia, nilai estetika, dan makhluk hidup lainnya. Berikut ini merupakan cara perhitungan ISPU dan batas ISPU dalam satuan SI (BLH, 2014)

$$I = \frac{Y_a - Y_b}{X_a - X_b} (X_p - X_b) + Y_b \quad (2.1)$$

dimana,

$I$  = ISPU terhitung

$Y_a$  = ISPU batas atas

$Y_b$  = ISPU batas bawah



$X_a$  = Ambien batas atas

$X_b$  = Ambien batas bawah






$X_p$  = Kadar ambien nyata yang diperoleh dari hasil pengukuran.

**Tabel 2.2** Nilai Konversi dalam Satuan SI

ISPU	PM10 ( $\mu\text{g}/\text{m}^3$ )	CO ( $\text{mg}/\text{m}^3$ )	O3 ( $\mu\text{g}/\text{m}^3$ )	SO2 ( $\mu\text{g}/\text{m}^3$ )	NO2 ( $\mu\text{g}/\text{m}^3$ )
0	0	0	0	0	0
50	50	80	5	120	0
100	150	365	10	235	0
200	350	800	17	400	1130
300	420	1600	34	800	2260
400	500	2100	46	1000	3000
500	600	2620	57,5	1200	3750

Setelah dikonversi dalam ISPU, maka kualitas udara dapat dikategorikan dalam 5 kategori berikut (BLH, 2014).

**Tabel 2.3** Kategori dan Rentang ISPU

Warna	Kategori	Rentang
	Baik	0 – 50
	Sedang	51 – 100
	Tidak sehat	101 – 199
	Sangat tidak sehat	200 – 299
	Berbahaya	300 – lebih

## 2.2 Jaringan Pemantauan Kualitas Udara Ambien

Pemantauan kualitas udara ambien di Surabaya dilakukan pada enam titik pemantauan, dimana masing-masing titik pemantauan mampu mewakili satu wilayah di Surabaya. Perencanaan jaringan pemantauan kualitas udara ambien dilakukan berdasarkan tingkat konsentrasi pencemar, penyebaran pencemar dan inventarisasi emisi. Penetapan jumlah jaringan ditentukan oleh faktor-faktor jumlah penduduk, tingkat pencemaran dan keragamannya serta kebijakan-kebijakan yang

berlaku. Kelima titik pemantauan tersebut adalah sebagai berikut (BLH, 2014).

**Tabel 2.4** Lokasi Stasiun Pemantauan Kualitas Udara Ambien

Stasiun	Wilayah	Lokasi Pemantauan	Peruntukan Lahan	Keterangan
SUF 1	Surabaya Pusat	Halaman Taman Prestasi, Jalan Ketabang Kali	Pusat kota, pemukiman, perkantoran	Kondisi rusak
SUF 2	Surabaya Utara	Halaman Kantor Kelurahan Perak Timur, Jalan Selangor	Perkantoran, dekat daerah industri, pergudangan	Dicopot pemasangannya
SUF 3	Surabaya Barat	Halaman Kantor Pembantu Walikota Surabaya Barat, Jalan Sukomanunggal	Pemukiman, daerah pinggir kota	Kondisi rusak
SUF 4	Surabaya Selatan	Halaman Kecamatan Gayungan, Jalan Gayungan	Pemukiman, dekat tol Surabaya-Gempol	Kondisi rusak
SUF 5	Surabaya Timur	Halaman Convention Hall, Jalan Arief Rahman Hakim	Pemukiman, kampus, perkantoran	Kondisi rusak
SUF 6	Surabaya Timur	Kebon Bibit Wonorejo, Jalan Kendalsari No. 117	Perumahan, ruang terbuka hijau, perdagangan, dan jasa komersial	Kondisi baik (Pemasangan baru tahun 2012)
SUF 7	Surabaya Selatan	Kelurahan Kebonsari, Jalan Kebonsari Manunggal 22	Perumahan, ruang terbuka hijau, perdagangan, dan jasa komersial	Kondisi baik (Pemasangan baru tahun 2013)

Selain membuat jaringan pemantauan, pemerintah juga membuat lima titik untuk menampilkan kondisi udara ambien Surabaya. Kelima titik yang dijadikan sebagai tempat *Public Data Display* adalah sebagai berikut

1. Depan Monumen Kapal Selam, Jl. Gubeng Pojok (Surabaya Pusat)
2. Depan BAPPEDA Propinsi Jatim, Jl. Pahlawan (Surabaya Utara)
3. Ring Road Jl. Mayjend Sungkono (Surabaya Barat)
4. Perempatan Jl. Dharmawangsa - Jl. Kertajaya (Surabaya Timur)
5. Depan BNI Graha Pangeran, Jl. A. Yani (Surabaya Selatan).

### 2.3 Statistika Deskriptif

Statistika merupakan metode pengumpulan data, analisis, interpretasi dan penyimpulan hasil analisis. Statistika terbagi menjadi statistika deskriptif dan statistika inferensia. Statistika deskriptif didefinisikan sebagai metode yang berkaitan dengan pengumpulan dan penyajian suatu gugus data sehingga memberikan informasi yang berguna (Walpole, 1995). Statistika deskriptif digunakan untuk memberikan informasi seputar data tanpa mengambil suatu keputusan (inferensi). Salah satu ukuran pemusatan data yang digunakan pada penelitian ini adalah rata-rata. Sedangkan ukuran penyebaran data yang digunakan pada penelitian ini adalah standar deviasi. Adapun penyajian informasi data digunakan plot *time series* dan *boxplot*.

#### 2.3.1 Rata-rata

Rata-rata atau *mean*, salah satu ukuran pemusatan data, merupakan jumlah keseluruhan data yang diamati, kemudian dibagi dengan banyaknya data. Secara matematis, rata-rata dapat ditulis sebagai berikut

$$\bar{Y} = \frac{\sum_{i=1}^n Y_i}{n} \quad (2.2)$$

dengan  $Y_i$  merupakan data pengamatan ke- $i$  dan  $n$  merupakan banyak data pengamatan.

### 2.3.2 Standar Deviasi

Standar deviasi merupakan salah satu ukuran penyebaran data. Nilai dari standar deviasi menunjukkan penyebaran dari data yang dianalisis. Kesimpulan yang diperoleh berdasarkan standar deviasi akan sama dengan kesimpulan yang diperoleh berdasarkan varians. Semakin kecil nilai standar deviasi, maka semakin kecil pula penyebaran data pengamatan atau variasi data yang diamati semakin kecil atau semakin seragam, demikian juga sebaliknya. Secara matematis, rata-rata dapat ditulis sebagai berikut

$$s = \sqrt{\frac{\sum_{i=1}^n (Y_i - \bar{Y})^2}{n-1}} \quad (2.3)$$

dengan


$\bar{Y}$  = rata-rata data pengamatan

$Y_i$  = data pengamatan ke- $i$

$n$  = banyak data pengamatan.

### 2.3.3 Plot Time Series

Plot *time series* merupakan plot yang menggambarkan nilai variabel random berdasarkan runtut waktu. Nilai variabel hasil pengamatan berada pada sumbu vertikal sedangkan interval waktu yang tetap berada pada sumbu horizontal. Plot *time series* dapat digunakan untuk mengidentifikasi pola data yang meliputi ada tidaknya unsur *trend* serta ada tidaknya pola *seasonal*. Selain itu, plot *time series* dapat digunakan untuk mengidentifikasi kestasioneran suatu data secara visual. Menurut Tufte dalam Cryer & Chan (2008: 8-9), *time series plot* merupakan desain grafik yang paling sering digunakan karena keteraturan pencatatan dalam detik, menit, jam, hari, bulan, tahun serta satuan waktu lain menjadikan interpretasi lebih efektif. Hal ini tidak dapat ditemukan pada komposisi grafik lain.



**Gambar 2.1** Contoh Plot *Time Series*

### 2.3.4 *Boxplot*

*Boxplot* merupakan ringkasan distribusi sampel yang disajikan secara grafis yang bisa menggambarkan bentuk distribusi data (*skewness*), ukuran tendensi sentral dan ukuran penyebaran (keragaman) data pengamatan. Selain itu, *boxplot* juga dapat menunjukkan ada tidaknya nilai outlier dan nilai ekstrim dari data pengamatan. Terdapat 5 ukuran statistik yang bisa dibaca dari *boxplot*, yaitu: nilai minimum (nilai observasi terkecil), Q1(kuartil pertama), Q2 (median), Q3 (kuartil ketiga) serta nilai maksimum (nilai observasi terbesar).

*Boxplot* dapat membantu dalam memahami karakteristik dari distribusi data. Selain itu, dapat digunakan untuk menilai kesimetrisan sebaran data. Panjang kotak menggambarkan tingkat penyebaran atau keragaman data pengamatan, sedangkan letak median dan panjang *whisker* menggambarkan tingkat kesimetrisannya (Chaniago, 2010).

## 2.4 Analisis *Time Series*

*Time series* merupakan serangkaian pengamatan yang dicatat secara urut berdasarkan interval waktu yang sama. Data pengamatan tersebut haruslah saling berkorelasi satu dengan lainnya (Wei, 2006: 1). Interval waktu yang digunakan

disesuaikan dengan kebutuhan. Contoh interval waktu yang dapat digunakan adalah harian, mingguan, dan bulanan (Gujarati, 2004: 25). Serangkaian data pengamatan yang telah dicatat dinyatakan sebagai variabel random  $Y_t$ , dimana  $t = 1, 2, \dots, n$  (Cryer & Chan, 2008: 11).

Tujuan dari dilakukan analisis *time series* adalah untuk memperoleh model yang sesuai dan memprediksi atau meramalkan kejadian beberapa tahap kedepan berdasarkan data masa lalu maupun data saat ini (Cryer & Chan, 2008: 1). Selain itu, analisis *time series* juga dapat digunakan untuk mengontrol suatu sistem agar optima (Wei, 2006: 1).

Wei (2006: 160) menjelaskan bahwa data *time series* dapat dibedakan menjadi musiman dan tidak musiman. Data dikatakan musiman apabila dalam waktu  $t$  berulang pada periode  $s$ . Hal ini berarti bahwa data-data yang dipisahkan dalam suatu musim penuh dapat memperlihatkan sifat yang sama pada musim berikutnya.

## 2.5 Stasioneritas

Proses stokastik dalam analisis *time series* harus memenuhi asumsi stasioner. Asumsi stasioner yang harus dipenuhi dalam analisis *time series* ada dua, yaitu stasioner dalam *mean* dan *varians*.

Suatu data dikatakan tidak stasioner dalam *varians* jika nilai *varians* dari data tersebut dipengaruhi oleh deret waktu. Apabila data tidak stasioner dalam *varians*, maka *series* tersebut ditransformasi untuk menstabilkan *varians*. Transformasi yang digunakan adalah transformasi *Box-Cox* (Wei, 2006: 85)

$$T(Y_t) = \frac{Y_t^\lambda - 1}{\lambda} \quad (2.4)$$

dimana  $\lambda$  merupakan parameter transformasi. Parameter transformasi ( $\lambda$ ) yang sering digunakan, serta bentuk transformasinya dapat dilihat pada Tabel 2.5.

Data dikatakan tidak stasioner dalam *mean* jika nilai *mean* data dipengaruhi oleh deret waktu. Apabila data tidak stasioner

(*nonstationary*) dalam *mean*, maka data tersebut direduksi dengan melakukan *differencing* sehingga menjadi stasioner dalam *mean*

$$\Delta Y_t = Y_t - Y_{t-1}. \quad (2.5)$$

**Tabel 2.5** Nilai  $\lambda$  dan Bentuk Transformasi

Nilai $\lambda$	Transformasi
-1	$\frac{1}{Y_t}$
-0,5	$\frac{1}{\sqrt{Y_t}}$
0	$\ln Y_t$
0,5	$\sqrt{Y_t}$
1	$Y_t$ (tidak ditransformasi)

## 2.6 Autocorrelation Function (ACF)

Autokorelasi atau yang dikenal dengan *autocorrelation function* (ACF) merupakan koefisien korelasi antara  $Y_t$  dan  $Y_{t-k}$  pada lag ke  $k$ . ACF biasanya dinotasikan dengan  $\rho_k$  dan didefinisikan sebagai berikut (Wei, 2006: 20)

$$\rho_k = \frac{\text{Cov}(Y_t, Y_{t+k})}{\sqrt{\text{Var}(Y_t)\text{Var}(Y_{t+k})}} = \frac{\text{Cov}(Y_t, Y_{t-k})}{\text{Var}(Y_t)} = \frac{\gamma_k}{\gamma_0} \quad (2.6)$$

dengan:

$$\rho_k = \text{ACF lag-}k$$

$$\text{Var}(Y_t) = \text{Var}(Y_{t+k}) = \gamma_0$$

$$\gamma_k = \text{Cov}(Y_t, Y_{t-k}) = E(Y_t - \mu)E(Y_{t+k} - \mu).$$

Secara matematis, fungsi autokorelasi yang dihitung berdasarkan sampel ( $\hat{\rho}_k$ ) dari suatu data time series  $\{Y_t\}$  dapat dituliskan sebagai berikut

$$\hat{\rho}_k = \frac{\hat{\gamma}_k}{\hat{\gamma}_0} = \frac{\sum_{t=1}^{n-k} (Y_t - \bar{Y})(Y_{t+k} - \bar{Y})}{\sum_{t=1}^n (Y_t - \bar{Y})^2}; k = 0, 1, 2, \dots \quad (2.7)$$

dengan  $\bar{Y} = \frac{\sum_{t=1}^n Y_t}{n}$ .

## 2.7 Partial Autocorrelation Function (PACF)

*Partial Autocorrelation Function* (PACF) merupakan sebuah fungsi dari ACF yang sangat berguna untuk menentukan orde  $p$  dari model AR (Tsay, 2010). Pada analisis time series, PACF dinotasikan dengan  $\phi_{kk}$  dengan persamaan sebagai berikut (Wei, 2006: 23)

$$\hat{\phi}_{k+1,k+1} = \frac{\hat{\rho}_{k+1} - \sum_{j=1}^k \hat{\phi}_{kj} \hat{\rho}_{k+1-j}}{1 - \sum_{j=1}^k \hat{\phi}_{kj} \hat{\rho}_j} \quad (2.8)$$

dan

$$\hat{\phi}_{k+1,j} = \hat{\phi}_{kj} - \hat{\phi}_{k+1,k+1} \hat{\phi}_{k,k+1-j}; j = 1, 2, \dots, k \quad (2.9)$$

dengan :

$\hat{\rho}_k$  = sample ACF lag- $k$

$\hat{\phi}_{kk}$  = sample PACF lag- $k$ .

## 2.8 Autoregressive Integrated Moving Average (ARIMA)

Model ARIMA merupakan model gabungan atau kombinasi dari model *Autoregressive* (AR) orde  $p$  dan *Moving Average* (MA) orde  $q$ , serta diikuti oleh proses *differencing* orde  $d$ . Model ini biasa digunakan untuk data yang bersifat linier dan univariat. Secara umum, bentuk model ARIMA ( $p, d, q$ ) adalah sebagai berikut (Wei, 2006: 72)

$$\phi_p(B)(1-B)^d Y_t = \theta_0 + \theta(B)a_t \quad (2.10)$$

dengan:

$p$  = orde dari *autoregressive* (AR)

$q$  = orde dari *moving average* (MA)

$d$  = orde dari *differencing*

$\phi_p(B)$  =  $1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p$

$\theta_q(B)$  =  $1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q$

$\theta_0$  =  $\mu(1 - \phi_1 - \dots - \phi_p)$

$(1-B)Y_t$  =  $Y_t - Y_{t-1}$

$a_t$  merupakan barisan *white noise* dengan rata-rata nol dan varians konstan sehingga  $a_t \sim WN(0, \sigma^2)$ , sedangkan  $B$  merupakan operator *backshift*.



## 2.9 Seasonal ARIMA (SARIMA)

Model ARIMA juga dapat diterapkan pada data yang memiliki pola musiman. Musiman merupakan kejadian berulang selama periode tertentu, artinya data-data yang dipisahkan dalam suatu musim penuh dapat memperlihatkan sifat yang sama pada musim berikutnya. Model ARIMA musiman, yang lebih dikenal dengan SARIMA, memiliki bentuk umum (Wei, 2006: 166)

$$\phi_p(B)\Phi_P(B^s)(1-B)^d(1-B^s)^DY_t = \theta_q(B)\Theta_Q(B^s)a_t \quad (2.11)$$

dengan

- $P$  = orde dari *seasonal autoregressive* (AR)
- $Q$  = orde dari *seasonal moving average* (MA)
- $D$  = orde dari *seasonal differencing*
- $s$  = periode *seasonal*
- $\Phi_P(B^s) = 1 - \Phi_1 B^s - \Phi_2 B^{2s} - \dots - \Phi_P B^{Ps}$
- $\Theta_P(B^s) = 1 - \Theta_1 B^s - \Theta_2 B^{2s} - \dots - \Theta_P B^{Ps}$ .

## 2.10 Double Seasonal ARIMA (DSARIMA)

Dalam kehidupan sehari-hari, seringkali ditemui data *time series* yang memiliki pola musiman lebih dari satu, seperti data konsumsi listrik jangka pendek (Taylor, 2003; Suhartono & Endharta, 2009). Apabila data mengandung dua pola musiman, maka disebut *Double Seasonal ARIMA* (DSARIMA). Secara matematis, model DSARIMA dapat ditulis sebagai berikut

$$\phi_p(B)\Phi_{P_1}(B^{s_1})\Phi_{P_2}(B^{s_2})(1-B)^d(1-B^{s_1})^{D_1}(1-B^{s_2})^{D_2}Y_t = \theta_q(B)\Theta_{Q_1}(B^{s_1})\Theta_{Q_2}(B^{s_2})a_t \quad (2.12)$$

dengan

- $P_1$  = orde dari *seasonal 1 autoregressive* (AR)
- $P_2$  = orde dari *seasonal 2 autoregressive* (AR)
- $Q_1$  = orde dari *seasonal 1 moving average* (MA)
- $Q_2$  = orde dari *seasonal 2 moving average* (MA)
- $D_1$  = orde dari *seasonal 1 differencing*
- $D_2$  = orde dari *seasonal 2 differencing*
- $s_1$  = periode *seasonal 1*
- $s_2$  = periode *seasonal 2*
- $\Phi_{P_1}(B^{s_1}) = 1 - \Phi_{11} B^{s_1} - \Phi_{12} B^{2s_1} - \dots - \Phi_{1P_1} B^{P_1 s_1}$

$$\begin{aligned}
\Phi_{P_2}(B^{s_2}) &= 1 - \Phi_{21}B^{s_1} - \Phi_{22}B^{2s_2} - \dots - \Phi_{2P_2}B^{P_2s_2} \\
\Theta_{Q_1}(B^{s_1}) &= 1 - \Theta_{11}B^{s_1} - \Theta_{12}B^{2s_1} - \dots - \Theta_{1P_1}B^{P_1s_1} \\
\Theta_{Q_2}(B^{s_2}) &= 1 - \Theta_{21}B^{s_1} - \Theta_{22}B^{2s_2} - \dots - \Theta_{2P_2}B^{P_2s_2}.
\end{aligned}$$

### 2.11 Model *Subset, Multiplikative dan Additive*

Model SARIMA dan DSARIMA merupakan model yang *multiplicative*. Model ini mengasumsikan bahwa parameter signifikan merupakan hasil dari *multiplicative* atau perkalian antara parameter *non*musiman dan musiman tanpa harus diuji secara statistik (Suhartono & Lee, 2011). Berdasarkan simulasi yang dilakukan oleh Suhartono dan Lee (2011), diperoleh kesimpulan bahwa model musiman ARIMA mengandung model *subset, multiplicative* dan *additive*.

#### 2.11.1 Model *Subset*

Misalkan diketahui model ARIMA(0,0,[1,11,12,13]) yang diidentifikasi sebagai *subset* SARIMA. Model dapat ditulis sebagai berikut

$$Y_t - \mu = a_t - \theta_1 a_{t-1} - \theta_{12} a_{t-12} - \theta_{13} a_{t-13} \quad (2.13)$$

dengan  $\theta_1, \theta_{12}$  dan  $\theta_{13}$  menunjukkan parameter MA. Secara matematis, ACF dari model dapat ditulis sebagai berikut

$$\rho_k = \begin{cases} \frac{-\theta_1 + \theta_{12}\theta_{13}}{(1+\theta_1^2+\theta_{12}^2+\theta_{13}^2)}; k = 1 \\ \frac{\theta_1\theta_{12}}{(1+\theta_1^2+\theta_{12}^2+\theta_{13}^2)}; k = 11 \\ \frac{-\theta_{12} + \theta_1\theta_{13}}{(1+\theta_1^2+\theta_{12}^2+\theta_{13}^2)}; k = 12 \\ \frac{\theta_{13}}{(1+\theta_1^2+\theta_{12}^2+\theta_{13}^2)}; k = 13 \\ 0; \text{lainnya.} \end{cases} \quad (2.14)$$

#### 2.11.2 Model *Multiplicative*

Misalkan diketahui model ARIMA(0,0,1)(0,0,1)<sup>12</sup> yang diidentifikasi sebagai *multiplicative* SARIMA. Model dapat ditulis sebagai berikut

$$Y_t - \mu = a_t - \theta_1 a_{t-1} - \theta_{12} a_{t-12} + \theta_1 \theta_{12} a_{t-13} \quad (2.15)$$

dengan  $\theta_1$  dan  $\theta_{12}$  menunjukkan parameter *nonmusiman* dan musiman MA. Model (2.15) sama dengan model (2.13) jika  $\theta_{13} = -\theta_1\theta_{12}$ . Sehingga dapat disimpulkan bahwa model *multiplicative* merupakan bagian dari model *subset*. Secara matematis, ACF dari model dapat ditulis sebagai berikut

$$\rho_k = \begin{cases} \frac{-\theta_1}{(1+\theta_1^2)} ; k = 1 \\ \frac{\theta_1\theta_{12}}{(1+\theta_1^2)(1+\theta_{12}^2)} ; k = 11, 13 \\ \frac{-\theta_{12}}{(1+\theta_{12}^2)} ; k = 12 \\ 0 ; \text{lainnya.} \end{cases} \quad (2.16)$$

Persamaan (2.16) menunjukkan bahwa ACF pada lag 11 sama dengan ACF pada lag 13.

### 2.11.3 Model Additive

Misalkan diketahui model ARIMA(0,0,[1,12]) yang diidentifikasi sebagai *additive* SARIMA. Model dapat ditulis sebagai berikut

$$Y_t - \mu = a_t - \theta_1 a_{t-1} - \theta_{12} a_{t-12} \quad (2.17)$$

dengan  $\theta_1$  dan  $\theta_{12}$  menunjukkan parameter *nonmusiman* dan musiman MA. Model (2.17) sama dengan model (2.13) jika  $\theta_{13} = 0$ . Sehingga dapat disimpulkan bahwa model *additive* merupakan bagian dari model *subset*. Secara matematis, ACF dari model dapat ditulis sebagai berikut

$$\rho_k = \begin{cases} \frac{-\theta_1}{(1+\theta_1^2+\theta_{12}^2)} ; k = 1 \\ \frac{\theta_1\theta_{12}}{(1+\theta_1^2+\theta_{12}^2)} ; k = 11 \\ \frac{-\theta_{12}}{(1+\theta_1^2+\theta_{12}^2)} ; k = 12 \\ 0 ; \text{lainnya.} \end{cases} \quad (2.18)$$

Persamaan (2.18) menunjukkan bahwa ACF pada lag 13 adalah nol. Hal inilah yang membedakan persamaan (2.18) dengan persamaan (2.14) dan persamaan (2.16).

## 2.12 Prosedur Box-Jenkins

Menurut Box dan Jenkins dalam Wei (2006), prosedur Box-Jenkins merupakan prosedur dengan pendekatan empirik yang diperlukan untuk mengidentifikasi orde dari model  $ARIMA(p, d, q)$ , mengestimasi dan menguji signifikansi parameter, pemeriksaan diagnostik, menentukan model terbaik serta melakukan peramalan. Prosedur ini bertujuan untuk membentuk model ARIMA.

### 2.12.1 Tahap Identifikasi

Pada tahap identifikasi model ARIMA terdapat empat langkah yang harus dilakukan, yaitu sebagai berikut (Wei, 2006: 108-110).

1. Membuat plot *time series* data dan memilih transformasi yang sesuai apabila data tidak stasioner dalam varians.
2. Menghitung *sample* ACF dan PACF untuk menguji stasioneritas data dalam mean. Apabila plot ACF turun lambat maka data belum stasioner dalam mean sehingga perlu dilakukan *differencing*.
3. Menghitung *sample* ACF dan PACF dari data yang telah stasioner untuk menentukan orde  $p$  dan  $q$ .
4. Menguji deterministik  $\theta_0$  apabila  $d > 0$ .

**Tabel 2.6** Karakteristik Plot ACF dan PACF pada Model ARIMA

Proses	ACF	PACF
AR( $p$ )	Turun cepat secara eksponensial atau sinusoidal	Terputus setelah lag $p$
MA( $q$ )	Terputus setelah lag $q$	Turun cepat secara eksponensial atau sinusoidal
ARMA( $p, q$ )	Turun cepat secara eksponensial atau sinusoidal	Turun cepat secara eksponensial atau sinusoidal
AR( $p$ ) atau MA( $q$ )	Terputus setelah lag $p$	Terputus setelah lag $q$
White Noise	Tidak ada yang signifikan	Tidak ada yang signifikan

Penentuan orde  $p$  dan  $q$  dari model ARIMA pada suatu data *time series* dilakukan dengan mengidentifikasi plot

*Autocorrelation Function* (ACF) dan *Partial Autocorrelation Function* (PACF) dari data yang telah stasioner. Petunjuk umum untuk penentuan orde  $p$  dan  $q$  pada suatu data *time series* yang sudah stasioner dapat diamati pada Tabel 2.6 (Bowerman & O'Connell, 1993: 475).

### 2.12.2 Tahap Estimasi Parameter

Tahapan yang dilakukan setelah mengidentifikasi model adalah mengestimasi parameter model ARIMA. Metode yang dapat digunakan untuk mengestimasi parameter adalah metode *moment*, metode *least square*, dan metode *maximum likelihood*. Diantara ketiga metode tersebut, metode *least square* adalah metode yang biasa digunakan. Metode *least square* dilakukan dengan cara meminimumkan jumlah kuadrat *error* (Cryer & Chan, 2008: 154-155)

Misalkan diberikan model AR(1) sebagai berikut

$$Y_t - \mu = \phi(Y_{t-1} - \mu) + a_t. \quad (2.19)$$

Proses selanjutnya adalah merubah persamaan (2.19) sedemikian hingga menjadi berikut

$$a_t = (Y_t - \mu) - \phi(Y_{t-1} - \mu). \quad (2.20)$$

Karena yang diketahui hanya  $Y_1, Y_2, \dots, Y_n$ , maka penjumlahan hanya bisa dilakukan dari  $t = 2$  sampai  $t = n$ . Hal ini disebut dengan *conditional sum-of-square function*. Berikut ini adalah fungsi tersebut

$$S_c(\phi, \mu) = \sum_{t=2}^n [(Y_t - \mu) - \phi(Y_{t-1} - \mu)]^2. \quad (2.21)$$

Parameter  $\mu$  dan  $\phi$  dapat diestimasi dengan menerapkan meminimumkan persamaan (2.21). Sehingga, diperoleh dua persamaan berikut ini untuk mengestimasi parameter

$$\frac{\partial S_c(\phi, \mu)}{\partial \mu} = \sum_{t=2}^n 2 [(Y_t - \mu) - \phi(Y_{t-1} - \mu)](-1 + \phi) = 0 \quad (2.22)$$

$$\frac{\partial S_c(\phi, \mu)}{\partial \phi} = \sum_{t=2}^n 2 [(Y_t - \mu) - \phi(Y_{t-1} - \mu)](Y_{t-1} - \mu) = 0 \quad (2.23)$$

Persamaan (2.22) dapat disederhanakan menjadi

$$\mu = \frac{1}{(n-1)(1-\phi)} [\sum_{t=2}^n Y_t - \phi \sum_{t=2}^n Y_{t-1}] \quad (2.24)$$

dan untuk  $n$  sangat besar maka

$$\frac{1}{(n-1)} \sum_{t=2}^n Y_t \approx \frac{1}{(n-1)} \sum_{t=2}^n Y_{t-1} \approx \bar{Y}. \quad (2.25)$$

Sehingga diperoleh estimator untuk  $\mu$  dengan cara mensubstitusikan persamaan (2.25) ke persamaan (2.24) dan menjadi

$$\hat{\mu} \approx \frac{1}{(1-\phi)} (\bar{Y} - \phi \bar{Y}) = \bar{Y}. \quad (2.26)$$

Namun, seringkali disebutkan bahwa nilai estimator  $\hat{\mu} = \bar{Y}$ . Selanjutnya adalah mensubstitusikan persamaan (2.26) ke dalam persamaan (2.23). Sehingga, diperoleh estimator  $\phi$

$$\hat{\phi} = \frac{\sum_{t=2}^n (Y_t - \bar{Y})(Y_{t-1} - \bar{Y})}{\sum_{t=2}^n (Y_{t-1} - \bar{Y})^2}. \quad (2.27)$$

Setelah memperoleh parameter  $\mu$  dan  $\phi$ , maka selanjutnya adalah menguji signifikansi parameter. Berikut ini adalah pengujian yang digunakan.

$H_0 : \phi_i = 0$ , dimana  $i = 1, 2, \dots, p$

$H_1 : \phi_i \neq 0$ , dimana  $i = 1, 2, \dots, p$

Statistik uji yang digunakan adalah sebagai berikut

$$t_{hitung} = \frac{\hat{\phi}_i}{SE(\hat{\phi}_i)}. \quad (2.28)$$

$H_0$  ditolak apabila  $|t_{hitung}| > t_{\frac{\alpha}{2}, (n-k)}$ , dimana  $n$  menunjukkan banyaknya observasi dan  $k$  menunjukkan banyaknya parameter dalam model. Parameter  $\theta$  pada model MA(1) dapat diestimasi dengan menerapkan langkah yang sama untuk menghitung  $\mu$  dan  $\phi$  pada model AR(1).

### 2.12.3 Tahap Cek Diagnosa

Setelah parameter dari model signifikan, maka tahap selanjutnya adalah pengujian residual yang diperoleh. Terdapat dua asumsi yang harus dipenuhi oleh residual, yaitu residual bersifat *white noise* dan berdistribusi normal.

Residual memenuhi asumsi white noise apabila residual saling independen dan identik. Pengujian asumsi dapat dilakukan dengan menggunakan uji *Ljung-Box* (Wei, 2006: 152-153). Berikut ini adalah hipotesis yang digunakan

$H_0$  :  $\rho_1 = \rho_2 = \dots = \rho_K = 0$  (residual bersifat *white noise*).

$H_1$  : Minimal ada satu  $\rho_k \neq 0, i = 1, 2, \dots, K$  (residual tidak bersifat *white noise*)

Statistik uji yang digunakan adalah sebagai berikut

$$Q = n(n+2) \sum_{k=1}^K \frac{\hat{\rho}_k^2}{n-k}. \quad (2.29)$$

Keputusan tolak  $H_0$  jika  $Q \geq \chi_{\alpha, (K-p-q)}^2$ , dimana  $K$  adalah lag maksimum, sedangkan  $p$  dan  $q$  adalah order dari model ARIMA( $p, d, q$ ).

Asumsi lain yang harus dipenuhi oleh residual adalah berdistribusi normal. Pengujian normalitas dapat dilakukan dengan menggunakan uji Kolmogorov-Smirnov. Hipotesis yang digunakan adalah sebagai berikut

$H_0$  :  $F(a_t) = F_0(a_t)$  atau residual berdistribusi normal

$H_1$  :  $F(a_t) \neq F_0(a_t)$  atau residual tidak berdistribusi normal.

Statistik uji yang digunakan adalah sebagai berikut

$$D = \text{Sup } |S(a_t) - F_0(a_t)| \quad (2.30)$$

dimana,

$S(a_t)$  : nilai peluang kumulatif berdasarkan data sampel

$F_0(a_t)$  : nilai peluang kumulatif dibawah  $H_0$ .

$H_0$  ditolak jika  $D > D_{\alpha, n}$ , dimana  $\alpha$  adalah taraf signifikansi dan  $n$  adalah banyaknya residual (Daniel, 2000: 343-345).

#### 2.12.4 Tahap Peramalan

Peramalan dilakukan dengan menggunakan model terbaik yang memenuhi kriteria kebaikan model. Jika terdapat lebih dari satu model memenuhi kriteria kebaikan model maka dipilih model yang memiliki kriteria kebaikan model secara *in sample* maupun *out sample* terkecil. Prinsip peramalan model ARIMA adalah meminimalkan *Mean Square Error* (MSE) hasil ramalan (Wei, 2006: 94-95).

Misalkan diketahui model ARIMA(1,0,1) atau ARMA(1,1). Secara matematis model dapat ditulis sebagai berikut

$$(1 - \phi B)(Y_t - \mu) = (1 - \theta B)a_t. \quad (2.31)$$

Langkah-langkah untuk melakukan peramalan adalah :

1. Menghitung ramalan  $\hat{Y}_n(h)$ .

Untuk  $t = n + h$ , maka persamaan (2.29) dapat ditulis sebagai berikut

$$Y_{n+h} = \mu + \phi(Z_{n+h-1} - \mu) + a_{n+h} - \theta a_{n+h-1}. \quad (2.32)$$

Sehingga,

$$\hat{Y}_n(1) = \mu + \phi(Y_n - \mu) - \theta a_n \quad (2.33)$$

dan

$$\hat{Y}_n(h) = \mu + \phi[\hat{Y}_n(h-1) - \mu]; h \geq 2 \quad (2.34)$$

2. Menghitung varians error  $\text{Var}(e_n(h)) = \sigma_a^2 \sum_{j=0}^{h-1} \psi_j^2$ .

Jika  $|\phi| < 1$ , maka varians erornya adalah

$$\text{Var}(e_n(h)) = \sigma_a^2 \left\{ 1 + \sum_{j=1}^{h-1} [\phi^{j-1}(\phi - \theta)]^2 \right\}. \quad (2.35)$$

Untuk  $h \rightarrow \infty$ , maka persamaan (2.35) akan konvergen menjadi

$$\sigma_a^2 \left[ 1 + \frac{(\phi - \theta)^2}{(1 - \phi^2)} \right]. \quad (2.36)$$

### 2.13 Pemilihan Kebaikan Model

Pemilihan model terbaik pada penelitian ini menggunakan kriteria kesalahan peramalan *Root Mean Square Error* (RMSE) untuk uji data *out sample*. Rumus RMSE pada adalah sebagai berikut (Wei, 2006: 181)

$$RMSE_{out} = \sqrt{\frac{\sum_{l=1}^L (Y_{n+l} - \hat{Y}_n(l))^2}{L}} \quad (2.37)$$

dengan

$Y_{n+l}$  = data *out sample*

$\hat{Y}_n(l)$  = nilai ramalan

$L$  = jumlah data *out sample*.



## **BAB III**

### **METODOLOGI PENELITIAN**

#### **3.1 Sumber Data**

Data yang digunakan dalam penelitian ini merupakan data sekunder yang diperoleh dari Badan Lingkungan Hidup (BLH) Surabaya. Data diperoleh dari alat yang dipasang pada stasiun pemantauan dan disajikan per jam dan diambil pada bulan Januari hingga Desember 2014.

Stasiun pemantau yang dipasang terdiri dari kontainer berAC lengkap dengan:

1. Alat pengukur kualitas udara, sistem pengukuran untuk data meteorologi, sensor untuk pemantauan suhu dan kelembaban dalam kontainer, sistem kontrol, unit sampel, penyediaan gas acuan, peralatan bantuan untuk aliran listrik dan transfer data.
2. Stasiun bekerja secara terus menerus, otomatis dan terkontrol oleh komputer.
3. Sistem pengontrolan dapat menyimpan parameter untuk 21 hari, kemudian data yang paling lama akan diganti dengan yang baru. Dalam masa 21 hari tersebut data harus ditransfer baik dengan cara online atau data dibawa ke laboratorium pemantau. Di laboratorium pemantau data dan fungsi sistem harus diperiksa dan dinyatakan sebagai data yang valid. Jika terjadi kesalahan fungsi dari system atau terdapat data yang tidak jelas, maka situasi ini harus diklarifikasikan dan data dinyatakan sebagai data yang valid atau tidak valid (invalid), dan jika perlu diikuti dengan pemeliharaan sistem.

Berikut ini adalah metode pengukuran PM<sub>10</sub> yang dilakukan untuk memperoleh data kualitas udara. Zat partikulat dengan ukuran kurang dari 10  $\mu\text{m}$  diukur dengan menghisap udara melalui unit sampel yang berbeda dan partikel terakumulasi pada filter tape. Instrumen (FH 62-1 dari Eberline) mengukur aliran udara secara terpaau melalui filter tape dan massa partikel pada

filter tape dengan sinar  $\beta$  attenuation. Filter tape akan maju setelah beberapa interval waktu atau massa akan melampaui jumlah tertentu.



**Gambar 3.1** Stasiun Pemantau Kualitas Udara


### **3.2 Lokasi Penelitian**

Berikut ini merupakan peta Kota Surabaya beserta letak dari stasiun pemantau kualitas udara yang terletak di Kebon Bibit Wonorejo dan Kantor Kelurahan Kebonsari. Letak lokasi stasiun dapat dilihat pada Gambar 3.1.

### **3.3 Variabel Penelitian**

Variabel yang digunakan dalam penelitian ini adalah sebagai berikut.

1.  $Y_{1,t}$  = Kandungan parameter  $PM_{10}$  di stasiun pemantau SUF 6.
  2.  $Y_{2,t}$  = Kandungan parameter  $PM_{10}$  di stasiun pemantau SUF 7.
- Struktur data dalam penelitian ini akan ditampilkan dalam Tabel 3.1.



**Gambar 3.2** Peta Kota Surabaya

**Tabel 3.1** Struktur Data Penelitian

Waktu (per 30 menit)	Variabel	
	PM <sub>10</sub> SUF 6	PM <sub>10</sub> SUF 7
1	$Y_{1,1}$	$Y_{2,1}$
2	$Y_{1,2}$	$Y_{2,2}$
⋮	⋮	⋮
50	$Y_{1,50}$	$Y_{2,50}$
⋮	⋮	⋮
$n - 47$	$Y_{1,(n-47)}$	$Y_{2,(n-47)}$
⋮	⋮	⋮
$n$	$Y_{1,n}$	$Y_{2,n}$

### 3.4 Metode Analisis

Dalam melakukan penelitian ini, digunakan dua metode untuk menyelesaikan rumusan masalah. Metode tersebut adalah:

1. Metode statistika deskriptif. Metode ini digunakan untuk mengetahui karakteristik kandungan PM10 dalam udara ambien Surabaya berdasarkan stasiun pemantau SUF 6 dan SUF 7.
2. Metode *time series* DSARIMA. Metode ini digunakan untuk membentuk model dengan orde yang sesuai dan akan digunakan untuk memprediksi kandungan PM10 di SUF 6 dan SUF 7.
3. Metode *time series* SARIMA. Metode ini digunakan untuk membentuk model dengan orde yang sesuai dan akan digunakan untuk memprediksi *peak* kandungan PM10 di SUF 6 dan SUF 7.


### 3.5 Langkah Analisis

Berdasarkan metode analisis yang digunakan, maka langkah-langkah analisis yang digunakan adalah sebagai berikut.

1. Menghitung statistika deskriptif, yaitu berupa rata-rata, standar deviasi, nilai maksimum, dan nilai minimum dari masing-masing variabel. Selain itu, analisis juga dilakukan dengan menggunakan plot *time series* dan *boxplot*. Selain dianalisis secara keseluruhan, data kandungan PM10 juga dianalisis berdasarkan jam, hari dan bulan. Hal ini dilakukan untuk mengetahui pola dan karakteristik kandungan PM10 dalam udara ambien Surabaya.
2. Membagi data menjadi *in sample* dan *out sample*. Data *in sample* adalah data kandungan PM10 tanggal 1 Januari hingga 30 November 2014. Data *out sample* adalah data kandungan PM10 tanggal 1 hingga 7 Desember 2014.
3. Membentuk model DSARIMA untuk stasiun pemantau SUF 6 dengan langkah-langkah sebagai berikut.
  - a. Mengidentifikasi data yang meliputi uji stasioneritas data, baik dalam *mean* maupun *varians*. Serta menentukan orde

- $p, d, q, P_1, P_2, D_1, D_2, Q_1, Q_2, s_1$  dan  $s_2$  berdasarkan plot ACF dan PACF.
- b. Mengestimasi parameter model ARIMA.
  - c. Menguji signifikansi parameter model ARIMA.
  - d. Melakukan cek diagnosa yang meliputi uji *white noise* dan uji distribusi normal. Untuk menguji *white noise* digunakan plot ACF dari residual model. Sedangkan untuk menguji distribusi normal digunakan uji Kolmogorov-Smirnov.
  - e. Memilih model terbaik dengan membandingkan nilai RMSE *out sample*. Model terbaik adalah model yang memiliki RMSE terkecil.
  - f. Melakukan peramalan menggunakan model terbaik.
4. Membentuk model DSARIMA untuk stasiun pemantau SUF 7 dengan langkah-langkah sebagai berikut.
- a. Mengidentifikasi data yang meliputi uji stasioneritas data, baik dalam *mean* maupun *varians*. Serta menentukan orde  $p, d, q, P_1, P_2, D_1, D_2, Q_1, Q_2, s_1$  dan  $s_2$  berdasarkan plot ACF dan PACF.
  - b. Mengestimasi parameter model ARIMA.
  - c. Menguji signifikansi parameter model ARIMA.
  - d. Melakukan cek diagnosa yang meliputi uji *white noise* dan uji distribusi normal. Untuk menguji *white noise* digunakan plot ACF dari residual model. Sedangkan untuk menguji distribusi normal digunakan uji Kolmogorov-Smirnov.
  - e. Memilih model terbaik dengan membandingkan nilai RMSE *out sample*. Model terbaik adalah model yang memiliki RMSE terkecil.
  - f. Melakukan peramalan menggunakan model terbaik.
5. Menarik kesimpulan.

3.6 Diagram Alir Penelitian



Gambar 3.3 Diagram Alir Penelitian

## BAB IV ANALISIS DAN PEMBAHASAN

Pada bagian ini diuraikan hasil analisis data kandungan PM10 di dua stasiun pengamatan di Surabaya, yaitu SUF 6 dan SUF 7. SUF 6 terletak di Kebon Bibit Wonorejo dan SUF 7 terletak di Kelurahan Kebonsari. Analisis meliputi analisis statistika deskriptif dan peramalan menggunakan metode *Double Seasonal ARIMA* (DSARIMA). Model terbaik akan dipilih berdasarkan kriteria *out sample* yaitu *Root Mean Square Error* (RMSE).

### 4.1 Statistika Deskriptif

Analisis statistika deskriptif bertujuan untuk mengeksplorasi informasi yang terkandung dalam data dan menggambarkan keadaan yang ada berdasarkan data yang diperoleh. Statistika deskriptif yang digunakan dalam penelitian ini adalah rata-rata, median, standar deviasi, nilai maksimum dan nilai minimum. Selain itu, plot *time series* dan *boxplot* juga digunakan dalam analisis.


**Tabel 4.1** Statistika Deskriptif Kandungan PM10 di SUF 6 dan SUF 7

Stasiun Pemantau	Rata-Rata	Median	Std Deviasi	Minimum	Maksimum
SUF 6	49,285	47,917	19,527	1,125	125,943
SUF 7	61,564	58,641	23,434	1,23	132

Tabel 4.1 menunjukkan bahwa rata-rata kandungan PM10 di SUF 7 lebih tinggi dibandingkan dengan SUF 6. Selain itu, nilai median yang merupakan nilai tengah dari suatu data juga menunjukkan bahwa kandungan PM10 di SUF 7 lebih tinggi daripada SUF 6. Berdasarkan dua statistika deskriptif tersebut, rata-rata dan median, maka dapat disimpulkan bahwa udara ambien di Surabaya masih baik dihirup oleh makhluk hidup. Akan tetapi, jika dieksplorasi kembali menggunakan nilai maksimum, nilai tertinggi dalam suatu data, maka akan menghasilkan kesimpulan yang berbeda. Kandungan PM10 tertinggi di dua

stasiun pemantau menunjukkan nilai yang lebih dari 100 yang berarti bahwa udara ambien pernah mencapai kondisi yang tidak sehat untuk dihirup oleh makhluk hidup.

Nilai standar deviasi menunjukkan tingkat keragaman kandungan PM10 dalam udara ambien Kota Surabaya. Keragaman kandungan PM10 yang terpantau melalui SUF 7 lebih tinggi dibandingkan dengan kandungan PM10 yang terpantau melalui SUF 6. Hal ini juga berarti bahwa kandungan PM10 di SUF 7 lebih fluktuatif dibandingkan dengan SUF 6.




**Gambar 4.1** Plot *Time Series* Kandungan PM10

Gambar 4.1 menunjukkan plot kandungan PM10 di Surabaya yang tercatat per jam dari periode 1 Januari 2015 hingga 31 Desember 2015. Garis biru menunjukkan plot *time series* data kandungan PM10 di SUF 6 dan garis hitam menunjukkan plot *time series* kandungan PM10 di SUF 7. Secara visual dapat diketahui bahwa kandungan PM10 di SUF 7 lebih tinggi daripada SUF 6. Selain itu, diketahui pula bahwa kandungan PM10 sering melebihi nilai 100, yaitu batas nilai yang menyatakan udara ambien baik untuk dihirup, terjadi pada bulan Agustus hingga November. Kandungan PM10 tinggi pada saat terjadi peralihan musim dari musim kemarau ke musim hujan.




Perbedaan kandungan PM10 di dua lokasi tersebut disebabkan oleh letak dan karakteristik masing-masing lokasi. Stasiun pemantau SUF 6 terletak di Kebon Bibit Wonorejo, Surabaya Timur, yang memiliki banyak sekali pohon rindang yang mampu mengurangi kandungan PM10 dalam udara ambien. Selain itu, lokasi ini tidak jauh dari Taman Hutan Mangrove Surabaya yang juga mampu mereduksi kandungan PM10. Sedangkan stasiun pemantau SUF 7 terletak di halaman Kantor Kelurahan Kebonsari, Surabaya Selatan, yang sebagian besar wilayahnya dimanfaatkan sebagai pemukiman penduduk dan perkantoran, sehingga tidak banyak terdapat pohon rindang di wilayah ini. Keberadaan pohon rindang mampu mereduksi kandungan PM10 karena salah satu parameter yang berpengaruh terhadap kandungan PM10, yaitu CO, diserap oleh pohon rindang yang ada.

Gambar 4.2 dan Gambar 4.3 menunjukkan bahwa kandungan PM10 memiliki fluktuasi yang berbeda setiap jamnya. Kandungan PM10 memiliki fluktuasi yang tinggi dimulai pukul 04.00 pagi seiring dengan dimulainya aktivitas seluruh lapisan masyarakat Surabaya, hingga pukul 16.00 atau pukul 04.00 sore seiring berakhirnya aktivitas utama masyarakat Surabaya. Fluktuasi kandungan PM10 yang tinggi di siang hari turut disumbang oleh asap kendaraan bermotor yang digunakan oleh masyarakat dalam beraktivitas (Buana, dkk., 2010). Sedangkan pada malam hari tidak terjadi fluktuasi yang tinggi kandungan PM10 karena aktivitas masyarakat yang tidak terlalu padat dan lebih banyak menghabiskan waktu dirumah untuk istirahat. Hal ini menjelaskan bahwa aktivitas yang dilakukan oleh masyarakat Surabaya mempengaruhi kandungan PM10 dalam udara ambien. Kandungan PM10 banyak melebihi batas 100 terjadi dimulai pukul 08.00 hingga 13.00 dimana pada jam ini lalu lintas menjadi lebih padat dibandingkan dengan jam lainnya.




**Gambar 4.2** Plot Time Series Kandungan PM10 Per Jam di SUF 6




**Gambar 4.3** Plot Time Series Kandungan PM10 Per Jam di SUF 7


Sebagaimana yang dapat diamati pada Gambar 4.4 dan Gambar 4.6, rata-rata kandungan PM10 terendah terjadi pada malam hingga dini hari dan rata-rata kandungan PM10 tertinggi terjadi pada siang hingga sore hari. Kondisi ini terjadi di dua lokasi pengamatan.




**Gambar 4.4** Plot Rata-rata Kandungan PM10 Per Jam Per Hari di SUF 6



**Gambar 4.5** Plot Standar Deviasi Kandungan PM10 Per Jam Per Hari di SUF 6



**Gambar 4.6** Plot Rata-rata Kandungan PM10 Per Jam Per Hari di SUF 7



**Gambar 4.7** Plot Standar Deviasi Kandungan PM10 Per Jam Per Hari di SUF 7

Rata-rata kandungan PM10 mencapai puncak tertinggi pada pukul 10.00 pagi hingga pukul 13.00 siang berdasarkan dua stasiun pemantau, SUF 6 dan SUF 7. Hal ini terjadi seiring dengan aktivitas lalu lintas yang padat di Surabaya, sehingga menyebabkan kandungan PM10 mencapai nilai tertinggi pada


siang hari. Gambar 4.4 dan Gambar 4.6 menunjukkan bahwa pada hari Minggu rata-rata kandungan PM10 dalam udara ambien merupakan yang paling rendah dibandingkan dengan hari lainnya. Hal ini disebabkan oleh sedikitnya masyarakat yang beraktivitas dan memilih beristirahat di rumah. Kesimpulan yang dapat diperoleh berdasarkan Gambar 4.4 dan Gambar 4.6 adalah rata-rata kandungan PM10 per hari baik untuk dihirup oleh makhluk hidup.

Gambar 4.5 dan Gambar 4.7 menunjukkan variasi dari kandungan PM10 dalam udara ambien. Berdasarkan kedua gambar tersebut, diketahui bahwa setiap hari pada pukul 10.00 hingga 13.00 keragaman nilai kandungan PM10 yang paling tinggi dibandingkan dengan jam lainnya.


Gambar 4.8 dan Gambar 4.9 menunjukkan rata-rata kandungan PM10 per jam per bulan. Di SUF 6, rata-rata kandungan PM10 pada bulan Agustus pukul 10.00 hingga 13.00 merupakan yang paling tinggi diantara bulan lainnya. Namun, tingginya tersebut masih termasuk dalam kategori tidak berbahaya karena nilainya berada dibawah 100. Sedangkan di SUF 7, rata-rata kandungan PM10 pada bulan September pukul 10.00 hingga 13.00 merupakan yang paling tinggi diantara bulan lainnya. Nilai rata-rata kandungan PM10 di bulan September dan Oktober di SUF 7 pada siang hari, pukul 10.00 hingga 13.00, melebihi nilai 100, sehingga tidak baik untuk dihirup oleh makhluk hidup.

Tingginya kandungan PM10 di bulan Agustus hingga Oktober disebabkan oleh beberapa faktor, diantaranya kecepatan dan arah angin, suhu, kelembaban dan musim. Pada bulan-bulan tersebut sedang terjadi musim kemarau. Pada musim kemarau, diketahui bahwa suhu dan kelembaban di suatu tempat akan meningkat. Apabila, suatu daerah tidak memiliki banyak pohon rindang, maka suhu dan kelembaban di daerah tersebut tinggi. Hal inilah yang menyebabkan rata-rata kandungan PM10 di SUF 7 tinggi. Pada bulan Januari, baik berdasarkan stasiun pemantauan SUF 6 dan 7, rata-rata kandungan PM10 merupakan yang paling


rendah dibandingkan dengan bulan lainnya. Hal ini disebabkan oleh musim hujan yang sedang terjadi yang mampu menurunkan suhu dan kelembaban di daerah tersebut, sehingga mampu mengurangi kandungan PM10 dalam udara ambien.




**Gambar 4.8** Plot Rata-rata Kandungan PM10 Per Jam Per Bulan di SUF 6



**Gambar 4.9** Plot Rata-rata Kandungan PM10 Per Jam Per Bulan di SUF 7



**Gambar 4.10** *Box Plot Kandungan PM10 Per Jam di SUF 6*



**Gambar 4.11** *Box Plot Kandungan PM10 Per Jam di SUF 7*


Gambar 4.10 menunjukkan bahwa data kandungan PM10 dalam udara ambien di SUF 6 memiliki banyak *outlier*. *Outlier* bernilai lebih dari interval kepercayaan. Hal ini mengindikasikan kandungan PM10 di SUF 6 lebih sering mencapai nilai tinggi daripada rendah. Namun, hanya sedikit kandungan PM10 yang



melebihi batas sehat, sehingga dapat dikatakan udara ambien Surabaya berdasarkan parameter PM10 sehat untuk dikonsumsi atau dihirup oleh masyarakat.


Sedangkan yang terjadi di SUF 7, *outlier* yang dihasilkan juga bernilai lebih dari interval kepercayaan, sehingga mengindikasikan bahwa udara ambien Surabaya berdasarkan parameter PM10 lebih sering tidak sehat untuk dikonsumsi atau dihirup oleh masyarakat Surabaya.

Kandungan PM10 berdasarkan hari aktif kerja maupun hari libur kerja dapat diamati dalam Gambar 4.12 dan Gambar 4.13. Secara umum, plot *time series* kandungan PM10 yang dicatat per jam tidak menunjukkan adanya tren, baik naik maupun turun, tetapi memiliki plot *time series* yang berbeda tiap harinya.




**Gambar 4.12** Plot *Time Series* Kandungan PM10 Per Hari di SUF 6

Plot *time series* yang berbeda setiap harinya disebabkan oleh varians kandungan PM10 dalam udara ambien berbeda tiap harinya. Gambar 4.14 menunjukkan bahwa varians kandungan PM10 terjadi pada hari Senin, Kamis dan Minggu lebih kecil dibandingkan dengan hari Selasa, Rabu, Jumat dan Sabtu. Selain itu, varians kandungan PM10 di SUF 7 lebih tinggi daripada varians di SUF 6.




**Gambar 4.13** Plot Time Series Kandungan PM10 Per Hari di SUF 7



**Gambar 4.14** Plot Varians Kandungan PM10 Per Hari di SUF 6 dan SUF 7

Pada hari Minggu, pola aktivitas masyarakat Surabaya hanya sederhana karena lebih memilih beraktivitas di dalam rumah dan sekitarnya. Sehingga menyebabkan masyarakat sedikit menggunakan kendaraan bermotor yang berpengaruh terhadap kandungan PM10. Sedangkan pada hari Senin, beberapa usaha

atau toko libur sehingga jumlah aktivitas pada lalu lintas berkurang. Hal inilah yang menyebabkan varians kandungan PM10 pada hari Senin dan Minggu lebih rendah dibandingkan dengan hari lainnya.




**Gambar 4.15** Plot Rata-rata Kandungan PM10 Per Hari di SUF 6 dan SUF 7


Selain varians yang hari lainnya yang kecil dibandingkan dengan hari lainnya, rata-rata kandungan PM10 baik di SUF 6 maupun SUF 7 pada hari Senin dan Minggu merupakan yang paling kecil dibandingkan dengan hari lainnya.

## 4.2 Pemodelan Menggunakan *Double Seasonal ARIMA*

Pemodelan dengan *double seasonal ARIMA* menggunakan prosedur Box-Jenkins dimulai dengan identifikasi kestasioneran data dalam *mean* dan varians. Data kandungan PM10 baik di SUF 6 maupun SUF 7 tidak stasioner dalam varians, sehingga dilakukan transformasi. Transformasi yang dilakukan adalah data asli ditambah 20 pada data di SUF 6 dan ditambah 30 pada data di SUF 7, kemudian di-*ln*-kan. Stasioneritas data dalam *mean* dapat diidentifikasi melalui plot ACF. Plot ACF yang memiliki pola turun sangat lambat mengindikasikan bahwa data tidak stasioner dalam *mean* sehingga perlu dilakukan *differencing*.




**Gambar 4.16** Plot ACF Data Kandungan PM10 di SUF 6




**Gambar 4.17** Plot PACF Data Kandungan PM10 di SUF 6

Gambar 4.16 dan Gambar 4.18 menunjukkan bahwa nilai ACF memiliki pola setiap kelipatan lag 168. Artinya, data kandungan PM10 dalam udara ambien per jam memiliki periode musiman mingguan atau per 168 jam. Sedangkan plot PACF pada

Gambar 4.17 dan Gambar 4.19 terlihat bahwa nilai PACF memiliki nilai yang signifikan pada kelipatan lag 24. Artinya, data kandungan PM10 dalam udara ambien memiliki periode musiman harian atau per 24 jam.




**Gambar 4.18** Plot ACF Data Kandungan PM10 di SUF 7




**Gambar 4.19** Plot PACF Data Kandungan PM10 di SUF 7

Data kandungan PM10 dalam udara ambien yang memiliki pola musiman harian dan mingguan selanjutnya dilakukan *differencing* untuk musiman dengan lag terbesar yaitu lag 168 untuk musiman mingguan dan lag 24 untuk musiman harian.




**Gambar 4.20** Plot ACF Data Kandungan PM10 di SUF 6 Setelah *Differencing* Lag 1, 24, dan 168




**Gambar 4.21** Plot PACF Data Kandungan PM10 di SUF 6 Setelah *Differencing* Lag 1, 24, dan 168

Karena plot ACF menunjukkan bahwa data setelah *differencing* 24 dan 168 belum stasioner, maka *differencing nonmusiman* pada lag 1. Plot ACF data setelah dilakukan *differencing* lag 1, 24 dan 168 sudah stasioner, baik dalam varians maupun dalam mean.



**Gambar 4.22** Plot ACF Data Kandungan PM10 di SUF 7 Setelah *Differencing* Lag 1, 24, dan 168



**Gambar 4.23** Plot PACF Data Kandungan PM10 di SUF 7 Setelah *Differencing* Lag 1, 24, dan 168

Plot ACF yang telah stasioner dapat dilihat pada Gambar 4.20 dan Gambar 4.22. Secara teoritis, plot ACF dari data yang telah stasioner memiliki pola *cut off* pada lag musiman 24 dan 168 dan *dies down* pada lag *non*musiman. Sedangkan plot PACF pada Gambar 4.21 dan Gambar 4.23 memiliki pola *dies down* pada lag musiman dan *non*musiman.

Berdasarkan plot ACF dan PACF dari data yang telah stasioner, diperoleh dua model dugaan untuk data kandungan PM10 di SUF 6 dan SUF 7. Berikut ini model dugaan yang diperoleh.

**Tabel 4.2** Model Dugaan DSARIMA Kandungan PM10

Stasiun Pemantau	Model Dugaan	
SUF 6	Model 1	ARIMA ([1,2,4,7,8,9,10,12,16,17,18],1,0)(1,1,1) <sup>24</sup> (0,1,1) <sup>168</sup>
	Model 2	ARIMA ([1,2,3,4,7,8,9,10,11,12,16,17,18],1,0) (1,1,1) <sup>24</sup> (0,1,1) <sup>168</sup>
SUF 7	Model 1	ARIMA ([11,2,7,9,10,11,12,16,17,19,23],1,[4,5, 8,20]) (0,1,1) <sup>24</sup> (0,1,1) <sup>168</sup>
	Model 2	ARIMA ([1,2,4,5,7,8,10,11,12,13,15,16,18,19, 20],1,0) (1,1,1) <sup>24</sup> (0,1,1) <sup>168</sup>

Orde-orde dalam model tersebut diperoleh dengan melihat lag-lag pada plot ACF dan PACF data yang sudah stasioner yang nilainya lebih besar dari batas signifikansi. Kemudian dilakukan pengujian pada lag-lag tersebut, dengan cara memasukkannya dalam model. Lag dikatakan signifikan pengaruhnya jika *p-value* lebih kecil dari taraf signifikansi  $\alpha$  yang digunakan. Lag-lag yang signifikan tersebut kemudian disebut *subset*.

Lag-lag yang diuji signifikansinya adalah lag *non*musiman antara lag 1 hingga lag 24, lag musiman 24 dan 168. Lag tersebut dipilih karena diduga kandungan PM10 dipengaruhi oleh sehari sebelumnya.

Setelah model dugaan diperoleh, maka langkah selanjutnya adalah mengestimasi dan menguji signifikansi parameter model. Hasil estimasi parameter model untuk stasiun pemantau SUF 6 dan SUF 7 dapat dilihat pada Tabel 4.3 dan Tabel 4.4.



**Tabel 4.3** Nilai Estimasi Parameter Model Dugaan untuk SUF 6

Parameter	Model 1		Model 2	
	<i>Estimate</i>	<i>P-value</i>	<i>Estimate</i>	<i>P-value</i>
$\Theta_1$	0,799	< 0,0001	0,798	< 0,0001
$\Theta_2$	0,84	< 0,0001	0,841	< 0,0001
$\phi_1$	0,477	< 0,0001	0,48	< 0,0001
$\phi_2$	-0,062	< 0,0001	-0,077	< 0,0001
$\phi_3$			0,034	0,006
$\phi_4$	-0,027	0,0075	-0,039	0,0004
$\phi_7$	-0,051	< 0,0001	-0,05	< 0,0001
$\phi_8$	-0,282	< 0,0001	-0,282	< 0,0001
$\phi_9$	0,128	< 0,0001	0,128	< 0,0001
$\phi_{10}$	-0,114	< 0,0001	-0,126	< 0,0001
$\phi_{11}$			0,032	0,0092
$\phi_{12}$	-0,059	< 0,0001	-0,071	< 0,0001
$\phi_{16}$	-0,154	< 0,0001	-0,152	< 0,0001
$\phi_{17}$	-0,071	< 0,0001	0,069	< 0,0001
$\phi_{18}$	-0,07	< 0,0001	-0,069	< 0,0001
$\Phi_1$	-0,052	0,0002	-0,053	0,0002

Semua *p-value* yang diperoleh bernilai kurang dari taraf signifikansi  $\alpha$  sebesar 0,1. Hal ini menunjukkan bahwa semua parameter dalam model dugaan, baik model dugaan untuk SUF 6 dan SUF 7, sudah signifikan.


Apabila parameter dalam model sudah signifikan, maka langkah selanjutnya adalah pengujian diagnostik residual. Pengujian dilakukan untuk mengetahui apakah residual telah memenuhi asumsi, baik *white noise* maupun berdistribusi normal. Pengujian asumsi *white noise* dilakukan dengan melihat plot ACF residual. Apabila tidak ada lag yang nilainya melebihi batas signifikansi, maka dapat disimpulkan bahwa asumsi *white noise* terpenuhi. Sedangkan pengujian asumsi distribusi normal dilakukan dengan menggunakan uji Kolmogorov-Smirnov.

**Tabel 4.4** Nilai Estimasi Parameter Model Dugaan untuk SUF 7


Parameter	Model 1		Model 2	
	<i>Estimate</i>	<i>P-value</i>	<i>Estimate</i>	<i>P-value</i>
$\theta_4$	0,032	0,0044		
$\theta_5$	0,039	0,0003		
$\theta_8$	0,206	< 0,0001		
$\theta_{20}$	0,022	0,0518		
$\Theta_1$	0,812	< 0,0001	0,807	< 0,0001
$\Theta_2$	0,852	< 0,0001	0,853	< 0,0001
$\phi_1$	0,233	< 0,0001	0,232	< 0,0001
$\phi_2$	0,072	< 0,0001	0,069	< 0,0001
$\phi_4$			-0,032	0,0044
$\phi_5$			-0,029	0,0116
$\phi_7$	-0,093	< 0,0001	-0,089	< 0,0001
$\phi_8$			-0,203	< 0,0001
$\phi_9$	-0,042	0,0002		
$\phi_{10}$	-0,069	< 0,0001	-0,053	< 0,0001
$\phi_{11}$	-0,035	0,0027	-0,039	0,0021
$\phi_{12}$	-0,05	< 0,0001	-0,059	< 0,0001
$\phi_{13}$			-0,032	0,0043
$\phi_{15}$			-0,042	0,0002
$\phi_{16}$	-0,055	< 0,0001	-0,097	< 0,0001
$\phi_{17}$	-0,02	0,0721		
$\phi_{18}$			-0,03	0,0068
$\phi_{19}$	-0,035	0,0017	-0,04	0,0004
$\phi_{20}$			-0,03	0,0092
$\phi_{23}$	0,022	0,0482		
$\Phi_1$			-0,042	0,0024

ACF dari residual model untuk SUF 6 dapat dilihat pada Gambar 4.24 dan SUF 7 pada Gambar 4.25. Dari gambar tersebut terlihat bahwa tidak ada lag yang nilainya melebihi batas

signifikansi sehingga dapat disimpulkan bahwa residual, baik residual model untuk SUF 6 maupun SUF 7, sudah memenuhi asumsi *white noise*.



**Gambar 4.24** Plot ACF Residual (a) Model 1 dan (b) Model 2 DSARIMA untuk SUF 6



**Gambar 4.25** Plot ACF Residual (a) Model 1 dan (b) Model 2 DSARIMA untuk SUF 7

Selanjutnya adalah pengujian asumsi distribusi normal pada residual model. Tabel 4.5 menunjukkan hasil dari pengujian residual menggunakan uji Kolmogorov-Smirnov. *P-value* uji Kolmogorov-Smirnov untuk keempat model bernilai kurang dari taraf signifikansi 0,05. Artinya, residual dari keempat model tidak berdistribusi normal. Residual tidak berdistribusi normal dikarenakan data kandungan PM10, baik di SUF 6 maupun SUF 7, memiliki banyak *outlier*.

Keempat model untuk SUF 6 dan SUF 7 yang memiliki parameter signifikan dan residual *white noise* selanjutnya digunakan untuk meramal hingga 168 tahap kedepan untuk

periode 1 hingga 14 Desember 2015. Data *out sample* dikurangi dengan hasil ramalan, kemudian dihitung RMSEnya.

**Tabel 4.5** Uji Asumsi Distribusi Normal Residual

Stasiun Pengamatan		D	P-value
SUF 6	Model 1	0,069	< 0,01
	Model 2	0,071	< 0,01
SUF 7	Model 1	0,095	< 0,01
	Model 2	0,096	< 0,01

**Tabel 4.6** RMSE *Out Sample* Model DSARIMA di SUF 6 dan SUF 7

Stasiun Pengamatan		<i>Out Sample</i>
SUF 6	Model 1	16,372
	Model 2	16,531
SUF 7	Model 1	14,284
	Model 2	14,159

RMSE *out sample* digunakan sebagai kriteria untuk memilih model terbaik. Nilai RMSE model 1 di SUF 6 lebih kecil dibandingkan dengan model 2. Sedangkan di SUF 7, model 2 memiliki RMSE yang lebih kecil dibandingkan dengan model 1. Sehingga disimpulkan bahwa model 1 merupakan model terbaik untuk meramalkan dan mengontrol kandungan PM10 di SUF 6 dan model 2 merupakan model terbaik untuk meramalkan dan mengontrol kandungan PM10 di SUF 7.


Apabila data kandungan PM10 dalam udara ambien Surabaya yang dipantau oleh stasiun pemantau SUF 6 dilambangkan dengan  $Y_t$  maka model DSARIMA terbaik dapat dituliskan sebagai berikut

$$(1 - \phi_1 B - \phi_2 B^2 - \phi_4 B^4 - \phi_7 B^7 - \phi_8 B^8 - \phi_9 B^9 - \phi_{10} B^{10} - \phi_{12} B^{12} - \phi_{16} B^{16} - \phi_{17} B^{17} - \phi_{18} B^{18})(1 - \Phi_1 B^{24})(1 - B)(1 - B^{24})(1 - B^{168})Y_t = (1 - \Theta_1 B^{24})(1 - \Theta_2 B^{168})a_t$$

Dan apabila data kandungan PM10 dalam udara ambien Surabaya yang dipantau oleh stasiun pemantau SUF 6 dilambangkan dengan  $Z_t$  maka model DSARIMA terbaik dapat dituliskan sebagai berikut


$$(1 - \phi_1 B - \phi_2 B^2 - \phi_4 B^4 - \phi_5 B^5 - \phi_7 B^7 - \phi_8 B^8 - \phi_{10} B^{10} - \phi_{11} B^{11} - \phi_{12} B^{12} - \phi_{13} B^{13} - \phi_{15} B^{15} - \phi_{16} B^{16} - \phi_{18} B^{18} - \phi_{19} B^{19} - \phi_{20} B^{20})(1 - \Phi_1 B^{24})(1 - B)(1 - B^{24})(1 - B^{168})Z_t = (1 - \Theta_1 B^{24})(1 - \Theta_2 B^{168})a_t$$

Hasil ramalan selama 168 tahap kedepan untuk periode 1 hingga 14 Desember 2014 menggunakan model DSARIMA terbaik di SUF 6 dan SUF 7 ditunjukkan oleh Gambar 4.26.




**Gambar 4.26** Hasil Ramalan Data *Out Sample* Kandungan PM10 di (a) SUF 6 dan (b) SUF 7

Hasil ramalan data *out sample* yang diramalkan 168 tahap kedepan menunjukkan bahwa kandungan PM10 pada hari Senin dan Minggu lebih rendah dibandingkan dengan hari lainnya. Hal ini sesuai dengan analisis statistika deskriptif yang telah dilakukan sebelumnya. Selain itu, plot rata-rata per jam pada Gambar 4.27 juga menunjukkan hasil yang sesuai dengan Gambar 4.4 dan Gambar 4.6, dimana kandungan PM10 pada siang hari lebih tinggi dibandingkan pada malam hari.



**Gambar 4.27** Rata-rata Hasil Ramalan Data *Out Sample* Kandungan PM10 di (a) SUF 6 dan (b) SUF 7


Selanjutnya adalah membandingkan hasil peramalan dengan data *in sample* dan *out sample*. Plot *time series* pada Gambar 4.28 dan Gambar 4.29 merupakan hasil perbandingan antara data aktual atau data asli dengan data ramalan.




**Gambar 4.28** Plot *Time Series* antara Data Aktual dengan Hasil Ramalan Kandungan PM10 di SUF 6

Gambar 4.28 dan Gambar 4.29 menunjukkan bahwa secara grafik hasil ramalan data *in sample* lebih baik dibandingkan dengan data *out sample*. Hal ini disebabkan oleh peramalan data *in sample* merupakan peramalan satu tahap kedepan sehingga

diperoleh RMSE yang kecil, sedangkan peramalan pada data *out sample* merupakan peramalan  $k$ -tahap kedepan secara langsung.



**Gambar 4.29** Plot *Time Series* antara Data Aktual dengan Hasil Ramalan Kandungan PM10 di SUF 7



**Gambar 4.30** *Iterative RMSE Out Sample*

Hasil ramalan yang kurang baik pada data *out sample* dapat dijelaskan oleh Gambar 4.30. Semakin banyak ramalan yang dilakukan maka semakin besar pula RMSE yang dihasilkan. Selain itu, dapat dilihat bahwa pada mulanya *iterative RMSE out sample* fluktuatif kemudian mencapai kondisi *steady state*, kondisi dimana nilai RMSE mulai terlihat konstan. Gambar 4.30 menunjukkan bahwa RMSE terkecil adalah hasil dai peramalan satu tahap kedepan, sehingga dapat disimpulkan bahwa peramalan kandungan PM10 terbaik untuk kedua lokasi pengamatan adalah peramalan satu tahap kedepan.

### 4.3 Statistika Deskriptif *Peak* Kandungan PM10

Selain melakukan pemodelan dan peramalan kandungan PM10 secara menyeluruh, juga akan dilakukan pemodelan dan peramalan berdasarkan *peak* atau jam-jam puncak dimana kandungan PM10 lebih tinggi dibandingkan jam lainnya. Analisis akan dilakukan pada kandungan PM10 saat pukul 10.00, 11.00, 12.00 dan 13.00. Berikut ini merupakan statistika deskriptif dari *peak* kandungan PM10 di SUF 6 dan SUF 7.


**Tabel 4.7** Statistika Deskriptif *Peak* Kandungan PM10 di SUF 6 dan SUF 7

Stasiun Pemantau	Pukul	Rata-Rata	Std Deviasi	Minimum	Maksimum
SUF 6	10.00	65,38	23,5	5	125,94
	11.00	65,34	22,52	12,16	123,15
	12.00	64,34	21,08	13,87	115,12
	13.00	62,23	19,76	11,95	107,87
SUF 7	10.00	80,75	26,77	15	124,5
	11.00	79,9	25,89	15	125,23
	12.00	77,98	24,66	15,5	129,25
	13.00	74,71	23,4	9,91	132


Tabel 4.7 menunjukkan bahwa rata-rata kandungan PM10 pada pukul 10.00, 11.00, 12.00 dan 13.00 baik di SUF 6 dan SUF 7 hampir sama. Demikian juga dengan varians datanya. Nilai maksimum yang pernah dicapai melebihi nilai 100, yang berarti



bahwa kandungan PM10 pada pukul ini mempunyai peluang untuk tidak sehat.



**Gambar 4.31** Plot *Time Series Peak* Kandungan PM10 di SUF 6



**Gambar 4.32** Plot *Time Series Peak* Kandungan PM10 di SUF 7

Gambar 4.31 dan Gambar 4.32 menunjukkan bahwa plot pada series terakhir, yang terjadi pada bulan September hingga November, lebih tinggi dibandingkan dengan bulan-bulan sebelumnya. Hal ini sesuai dengan Gambar 4.8 dan Gambar 4.9

yang menunjukkan bahwa pada bulan September hingga November, *peak* kandungan PM10 lebih tinggi dibandingkan dengan bulan lainnya.


#### 4.4 Pemodelan ARIMA pada *Peak* Kandungan PM10

Analisis yang dilakukan pada sub bab ini adalah melakukan pemodelan dan peramalan *peak* kandungan PM10 di SUF 6 dan SUF 7. Langkah pertama yang dilakukan adalah membagi data menjadi data *in sample* dan *out sample*. Jumlah data *in sample* yang digunakan adalah 358 dan data *out sample* 7.


Langkah selanjutnya adalah menguji kestasioneran data. Data *Peak* kandungan PM10 di SUF 6 dan SUF 7 sudah stasioner dalam varians, namun belum stasioner dalam *mean* yang dapat dilihat pada Gambar 4.33 dan Gambar 4.34. Selain menunjukkan bahwa data belum stasioner dalam *mean*, Gambar 4.33 dan Gambar 4.34 menunjukkan bahwa data memiliki pola musiman 7 sehingga untuk mencapai stasioner dalam *mean* harus *didifferencing* pada lag musiman 7.

Setelah *didifferencing* pada lag musiman 7, plot ACF *peak* kandungan PM10 di SUF 6 dan SUF 7 sudah stasioner dalam *mean*. Sehingga analisis dapat dilanjutkan dengan menentukan orde yang sesuai berdasarkan plot ACF dan PACF yang sudah stasioner. Plot ACF stasioner *peak* kandungan PM10 di SUF 6 dapat dilihat pada Gambar 4.35 dan SUF 7 pada Gambar 4.37. Sedangkan plot PACF stasioner *peak* kandungan PM10 di SUF 6 dapat dilihat pada Gambar 4.36 dan SUF 7 pada Gambar 4.38.


Plot ACF *peak* kandungan PM10, baik di SUF 6 maupun SUF 7, memiliki pola *cut off* pada lag musimannya dan memiliki pola *diesdown* pada plot PACF. Pada lag *non*musimannya, *peak* kandungan PM10 baik di SUF 6 maupun SUF 7 memiliki pola *diesdown* pada plot ACF dan PACF.




**Gambar 4.33** Plot ACF *Peak* Kandungan PM10 di SUF 6 pukul (a)10.00, (b)11.00, (c)12.00 dan (d)13.00




**Gambar 4.34** Plot ACF *Peak* Kandungan PM10 di SUF 7 pukul (a)10.00, (b)11.00, (c)12.00 dan (d)13.00




**Gambar 4.35** Plot ACF *Peak* Kandungan PM10 di SUF 6 pukul (a)10.00, (b)11.00, (c)12.00 dan (d)13.00 Setelah *Differencing* 7



**Gambar 4.36** Plot PACF *Peak* Kandungan PM10 di SUF 6 pukul (a)10.00, (b)11.00, (c)12.00 dan (d)13.00 Setelah *Differencing* 7



**Gambar 4.37** Plot ACF *Peak* Kandungan PM10 di SUF 7 pukul (a)10.00, (b)11.00, (c)12.00 dan (d)13.00 Setelah *Differencing* 7



**Gambar 4.38** Plot PACF *Peak* Kandungan PM10 di SUF 7 pukul (a)10.00, (b)11.00, (c)12.00 dan (d)13.00 Setelah *Differencing* 7

Berdasarkan plot ACF dan PACF dari data yang telah stasioner, diperoleh model dugaan yang sama pada pukul 10.00, 11.00, 12.00 dan 13.00 di SUF 6 yaitu ARIMA (1,0,2)(0,1,1)<sup>7</sup> dan di SUF 7 adalah ARIMA (1,0,0)(0,1,1)<sup>7</sup>.

**Tabel 4.8** Estimasi Parameter Model Dugaan *Peak* Kandungan PM10 di SUF 6

Pukul	10.00		11.00	
Parameter	Estimasi	P-value	Estimasi	P-value
$\theta_1$	0,367	0,0002	0,405	< 0,0001
$\theta_2$	0,195	0,0121	0,207	0,0064
$\Theta_1$	0,895	< 0,0001	0,902	< 0,0001
$\phi_1$	0,851	< 0,0001	0,869	< 0,0001
Pukul	12.00		13.00	
Parameter	Estimasi	P-value	Estimasi	P-value
$\theta_1$	0,448	< 0,0001	0,474	< 0,0001
$\theta_2$	0,226	0,002	0,236	0,001
$\Theta_1$	0,902	< 0,0001	0,909	< 0,0001
$\phi_1$	0,892	< 0,0001	0,904	< 0,0001


**Tabel 4.9** Estimasi Parameter Model Dugaan *Peak* Kandungan PM10 di SUF 7

Pukul	10.00		11.00	
Parameter	Estimasi	P-value	Estimasi	P-value
$\theta_1$	0,252	0,0112	0,232	0,0177
$\Theta_1$	0,839	< 0,0001	0,837	< 0,0001
$\phi_1$	0,703	< 0,0001	0,699	< 0,0001
Pukul	12.00		13.00	
Parameter	Estimasi	P-value	Estimasi	P-value
$\theta_1$	0,243	0,0159	0,231	0,0324
$\Theta_1$	0,837	< 0,0001	0,835	< 0,0001
$\phi_1$	0,692	< 0,0001	0,659	< 0,0001


Semua *p-value* yang diperoleh bernilai kurang dari taraf signifikansi  $\alpha$  sebesar 0,1. Hal ini menunjukkan bahwa semua parameter dalam model dugaan *peak* kandungan PM10, baik model dugaan untuk SUF 6 dan SUF 7, sudah signifikan.

Apabila parameter dalam model sudah signifikan, maka langkah selanjutnya adalah pengujian diagnostik residual. Pengujian asumsi *white noise* dilakukan dengan melihat plot ACF residual. Apabila tidak ada lag yang nilainya melebihi batas signifikansi sampai lag 7, maka dapat disimpulkan bahwa asumsi *white noise* terpenuhi. Selain itu juga digunakan uji Ljung Box untuk menguji *white noise*. Sedangkan pengujian asumsi distribusi normal dilakukan dengan menggunakan uji Kolmogorov-Smirnov.

ACF dari residual terlihat bahwa tidak ada lag yang nilainya melebihi batas signifikansi sehingga dapat disimpulkan bahwa residual, baik residual model *peak* untuk SUF 6 maupun SUF 7, sudah memenuhi asumsi *white noise*.



**Gambar 4.39** Plot ACF Residual Model *Peak* Kandungan PM10 di SUF 6 pukul (a)10.00, (b)11.00, (c)12.00 dan (d)13.00



**Gambar 4.40** Plot ACF Residual Model *Peak* Kandungan PM10 di SUF 7 pukul (a)10.00, (b)11.00, (c)12.00 dan (d)13.00

Selanjutnya adalah pengujian asumsi distribusi normal pada residual model *peak*. Tabel 4.10 menunjukkan hasil dari pengujian residual menggunakan uji Kolmogorov-Smirnov.

**Tabel 4.10** Pengujian Disrtribusi Normal *Peak* Kandungan PM10

Stasiun Pemantau	Pukul	D	P-value
SUF 6	10.00	0,05	0,0473
	11.00	0,054	0,022
	12.00	0,063	< 0,01
	13.00	0,062	< 0,01
SUF 7	10.00	0,051	0,037
	11.00	0,047	0,0837
	12.00	0,043	0,1418
	13.00	0,05	0,0488

P-value uji Kolmogorov-Smirnov untuk model *peak* di SUF 6 bernilai kurang dari taraf signifikansi 0,05. Artinya, residual dari



tidak berdistribusi normal. Sedangkan residual model untuk pukul 12.00 dan 13.00 di SUF 7 memiliki *p-value* yang lebih besar dari taraf signifikansi 0,05. Artinya, residual berdistribusi normal dan untuk residual model pukul 10.00 dan 11.00 di SUF 7 tidak berdistribusi normal.

Setelah mengestimasi dan menguji signifikansi parameter, serta menguji diagnostik residualnya maka langkah selanjutnya adalah melakukan peramalan pada data *out sample*. Peramalan dilakukan dengan menggunakan model dugaan untuk *peak* kandungan PM10 di SUF 6 dan SUF 7. Peramalan yang dilakukan adalah peramalan 7 tahap kedepan. Namun, hasil ramalan kurang baik karena pola yang dimiliki oleh hasil ramalan dan data *out sample* berbeda.

## **BAB V**

### **KESIMPULAN DAN SARAN**

#### **5.1 Kesimpulan**

Berdasarkan analisis data kandungan PM10 tahun 2014, maka didapatkan beberapa kesimpulan sebagai berikut.

1. Data kandungan PM10 yang dipantau oleh stasiun pemantau SUF 7 lebih tinggi dibandingkan dengan yang dipantau oleh SUF 6. Perbedaan ini disebabkan oleh karakteristik kedua lokasi yang berbeda, dimana di sekitar stasiun pemantau SUF 6 lebih banyak terdapat pohon rindang dan hutan bakau yang mampu mereduksi kadar polutann PM10, sedangkan di SUF 7 tidak.
2. Data kandungan PM10 yang dicatat secara per jam tahun 2014, baik di SUF 6 maupun SUF 7, memiliki pola musiman harian dan bulanan. Rata-rata kandungan PM10 tinggi pada saat siang hari, dimana aktivitas masyarakat sangat padat. Sehingga pola yang dimiliki adalah kandungan PM10 rendah pada malam hari dan tinggi pada siang hari. tingginya kandungan PM10 dimulai pukul 10.00 hingga 13.00.
3. Apabila dianalisis berdasarkan rata-rata per hari, maka kandungan PM10 pada hari Senin dan Minggu lebih rendah dibandingkan dengan hari lainnya. Sedangkan apabila dianalisis berdasarkan rata-rata per bulan, maka kandungan PM10 pada bulan-bulan musim hujan lebih rendah dibandingkan bulan-bulan musim kemarau. Hal ini disebabkan oleh beberapa faktor, diantaranya kecepatan dan arah angin, suhu dan kelembaban yang ditimbulkan.
4. Kandungan PM10 yang dipantau oleh stasiun pemantau SUF 7 memiliki *outlier* yang lebih banyak dibandingkan dengan SUF 6. *Outlier* merupakan nilai yang berada diluar interval, sehingga menyebabkan data kandungan PM10 tidak berdistribusi normal.
5. Model ARIMA terbaik berdasarkan kriteria *out sample* RMSE untuk meramalkan kandungan PM10 per jam di SUF

6 adalah ARIMA  $([1,2,4,7,8,9,10,12,16,17,18],1,0)(1,1,1)^{24}$   
 $(0,1,1)^{168}$  dan model terbaik untuk di SUF 7 adalah ARIMA  
 $([1,2,4,5,7,8,10,11,12,13,15,16,18,19,20],1,0)(1,1,1)^{24}$   
 $(0,1,1)^{168}$ .

6. Model ARIMA yang diperoleh untuk meramalkan kandungan PM10 pada saat jam sibuk, yaitu pukul 10.00, 11.00, 12.00 dan 13.00 untuk stasiun pemantau SUF 6 adalah ARIMA  $(1,0,2)(0,1,1)^7$  dan di SUF 7 adalah ARIMA  $(1,0,0)(0,1,1)^7$ .

## 5.2 Saran

Setelah melakukan penelitian ini, maka beberapa hal yang perlu diperbaiki pada penelitian berikutnya adalah pemodelan kandungan PM10 menggunakan *Double Seasonal ARIMA* (DSARIMA) dengan menambahkan pendekatan *percentile error bootstrap* untuk mengatasi interval hasil ramalan yang semakin lebar jika dilakukan beberapa tahap kedepan. Selain itu, untuk mengatasi residual yang tidak berdistribusi normal dapat digunakan deteksi *outlier* pada residual model ARIMA yang dihasilkan.

Saran yang dapat diberikan untuk Pemerintah Kota Surabaya adalah menambah jumlah pohon rindang di kawasan Kebonsari untuk mereduksi kandungan PM10 dalam udara. Selain itu, Pemerintah juga dapat meramalkan kandungan PM10 satu jam kedepan menggunakan model ARIMA yang diperoleh.

## DAFTAR PUSTAKA

- Afroz, R., Hassan, M. N. & Ibrahim, N. A. (2003). Review of Air Pollution and Health Impacts in Malaysia. *Academic Press: Environmental Research* 92, 71-77.
- Amstrong, J. S. (2007). Significance Test Harm Progress in Forecasting. *Elsevier: International Journal of Forecasting* 23, 321-327.
- Anggraeni, A. D. & Suharsono, A. (2014). Peramalan Penjualan Sepeda Motor Tiap Jenis di Wilayah Surabaya dan Blitar dengan Model ARIMA Box-Jenkins dan *Vector Autoregressive* (VAR). *Jurnal Sains dan Seni POMITS Vol. 3 No. 2*, 2337-3520.
- Badriyah, A. S. R. & Suharsono, A. (2014). Peramalan Permintaan Penjualan Sepeda Motor di PT. “A” dengan Menggunakan ARIMAX dan VARX (Studi Kasus di Kabupaten Ponorogo. *Jurnal Sains dan Seni POMITS Vol. 3 No. 2*, 2337-3520.
- BLH. (2014). *Laporan Kegiatan Operasional dan Pengadaan Stasiun Monitoring Udara Ambien (Kode Kegiatan 1.08.16.0023)*. Surabaya: Badan Lingkungan Hidup.
- Bowman, B. L. & O'Connell, R. T. (1993). *Forecasting and Time Series: An Applied Approach*, (3<sup>rd</sup> Ed). Duxbury Press: USA
- Bowman, K. W. (2013). Toward the Next Generation of Air Quality Monitoring: Ozone. *Elsevier: Atmospheric Environment* 80, 571-583.
- Chaniago, J. (2010). Mengenal Boxplot. Dipetik 4 Juli 2014, dari <http://juniadichaniago.wordpress.com>.
- Cryer, J. D., & Chan, K.-S. (2008). *Time Series Analysis With Applications in R, Second Edition*. New York: Springer.

- Daniel, W. (2000). *Applied Nonparametric Statistics (2nd Ed.)*. Boston: Duxbury Press.
- Desvina, A. P. (2011). *Peramalan Particulate Matter ( $PM_{10}$ ) di Kajang Malaysia dengan Menggunakan Model Autoregressive*. Riau: Jurusan Matematika Fakultas Sains dan Teknologi UIN Suska.
- Ditago, A. P., Suharsono, A. & Suhartono. (2013). Perbandingan Model ARIMAX dan Fungsi Transfer untuk Peramalan Konsumsi Energi Listrik di Jawa Timur. *Jurnal Sains dan Seni POMITS Vol. 2 No. 2*, 2337-3520.
- Gooijer, J. G. D. & Hyndman, R. J. (2006). 25 Years of Time Series Forecasting. *International Journal of Forecasting*, 22, 443-473.
- Gujarati, D. N. (2004). *Basic Econometrics 4th Edition*. New York: McGraw-Hill.
- Badriyah, A. S. R. & Suharsono, A. (2014). Analisis Peramalan Penjualan Sepeda Motor di Kabupaten Ngawi Dengan ARIMA dan ARIMAX. *Jurnal Sains dan Seni POMITS Vol. 3 No. 2*, 2337-3520.
- Kostenko, A. V. & Hyndman, R. J. (2008). Forecasting without Significance Test?. <http://robjhyndman.com/papers/sst2.pdf>.
- Khusna, H. (2015). *Pendekatan Percentile Error Bootstrap pada Model Double Seasonal Holt-Winters, Double Seasonal ARIMA, dan Naive untuk Peramalan Beban Listrik Jangka Pendek Area Jawa Timur-Bali*. Surabaya: Jurusan Statistika ITS.
- Mohamed, N. dkk. (2010). Double Seasonal ARIMA Model for Forecasting Load Demand. *MATEMATIKA Vol. 26 Department of Mathematical Sciences, UTM*, 217-231.

- Nuraini. (2004). *Analisis Statistik Terhadap Polutan Udara Partikulat (PM10) Berdasarkan Pengukuran Stasiun Pemantau Taman Prestasi dengan Metode Bootstrap Time Series*. Surabaya: Jurusan Statistika ITS.
- Putri, I. K. (2015). *Deteksi Outlier pada Model ARIMA Musiman Ganda untuk Peramalan Beban Listrik Jangka Pendek di Jawa Timur*. Surabaya: Jurusan Statistika ITS.
- Suhartono, & Lee, M. H. (2011). Forecasting of Tourist Using Subset, Multiplicative or Additive Seasonal ARIMA Model. *MATEMATIKA Vol. 27 Department of Mathematical Sciences, UTM* , 169-182.
- Lee, M. H., dkk. (2012). Seasonal ARIMA for Forecasting Air Pollution Index: A Case Study. *American Journal of Applied Sciences* 9,570-578.
- Syafei. (2012, Juni 5). *Data Kualitas Udara Kota Surabaya*. Dipetik Desember 26, 2014, dari Catatan Teknik Lingkungan: <http://envirodiary.com/id/data-kualitas-udara-kota-surabaya.php>
- Tamin, O. Z. (1992). *Metodologi Peramalan Lalu Lintas Perkotaan untuk Negara Berkembang*. Jakarta: PT Perentjana Djaja.
- Tamin, O. Z. (1992). *Metodologi Peramalan Lalu Lintas Perkotaan untuk Negara Berkembang*. Jakarta: PT Perentjana Djaja.
- Tsay, R. S. (2010). *Analysis of Financial Time Series: Financial Ecnometrics (3rd Ed.)*. New York: John Wiley & Sons, Inc.
- Walpole, R. E. (1995). *Pengantar Statistika*. Jakarta: PT Gramedia Pustaka Utama.
- Wei, W. W. S. (2006). *Time Series Analysis: Univariate and Multivariate Methods, Second Edition*. United States: Pearson Education, Inc.

Yu, H.-L., Lin, Y.-C., & Kuo, Y.-M. (2015). A Time Series Analysis of Multiple Ambient Pollutants to Investigate the Underlying Air Pollution Dynamics and Interactions. *Elsevier: Chemosphere*

## LAMPIRAN

**Lampiran 1.** Data Kandungan PM<sub>10</sub> di SUF 6 dan SUF 7 Tahun 2014

No.	Bulan	Tgl	Waktu	Periode	PM <sub>10</sub> SUF 6	PM <sub>10</sub> SUF 7
1	Jan	1	1:00:00 AM	1	33,355	33,355
2	Jan	1	2:00:00 AM	2	37,22	37,22
3	Jan	1	3:00:00 AM	3	40,45	40,45
4	Jan	1	4:00:00 AM	4	41,835	41,835
5	Jan	1	5:00:00 AM	5	41,145	41,145
6	Jan	1	6:00:00 AM	6	41,865	41,865
7	Jan	1	7:00:00 AM	7	37,58	37,58
8	Jan	1	8:00:00 AM	8	46,03	46,03
9	Jan	1	9:00:00 AM	9	46,085	46,085
10	Jan	1	10:00:00 AM	10	42,27	42,27
11	Jan	1	11:00:00 AM	11	42	42
12	Jan	1	12:00:00 PM	12	42,965	42,965
13	Jan	1	1:00:00 PM	13	47,91	47,91
14	Jan	1	2:00:00 PM	14	47,065	47,065
15	Jan	1	3:00:00 PM	15	50,86	50,86
16	Jan	1	4:00:00 PM	16	43,1	43,1
17	Jan	1	5:00:00 PM	17	45,06	45,06
18	Jan	1	6:00:00 PM	18	46,08	46,08
...	...	...	...	...	...	...
8755	Des	31	7:00:00 PM	19	44,79	54,49
8756	Des	31	8:00:00 PM	20	46,04	56,18
8757	Des	31	9:00:00 PM	21	51,5275	55,3375
8758	Des	31	10:00:00 PM	22	53,02	56,1375
8759	Des	31	11:00:00 PM	23	53,555	55
8760	Des	31	12:00:00 AM	24	54,5	54,73



**Lampiran 2.** Syntax Pemodelan 1 DSARIMA Data Kandungan PM<sub>10</sub> di SUF 6 dengan SAS

```

data polusi;
input y;
datalines;
3.97697
4.04690
4.10182
4.12447
4.11325
4.12495
4.05318
4.19011
4.19094
4.13148
4.12713
...
...
...
4.11145
4.13316
4.12431
;
proc arima data=polusi;
identify var=y(1,24,168);
estimate p=(1,2,4,7,8,9,10,12,16,17,18)(24) q=(24)(168)
noconstant method=cls;
forecast out=ramalan lead=168;
run;
proc univariate data=ramalan normal;
var residual;
run;
proc export data=ramalan
outfile="E:\SUF 6 model 1.xls"
dbms=excel97
replace;
run;

```

**Lampiran 3.** Syntax Pemodelan 2 ARIMA Data Kandungan  $PM_{10}$  di SUF 6 dengan SAS

```

data polusi;
input y;
datalines;
3.97697
4.04690
4.10182
4.12447
4.11325
4.12495
4.05318
4.19011
4.19094
4.13148
4.12713
...
...
...
4.11145
4.13316
4.12431
;
proc arima data=polusi;
identify var=y(1,24,168);
estimate p=(1,2,3,4,7,8,9,10,11,12,16,17,18)(24) q=(24)(168)
noconstant method=cls;
forecast out=ramalan lead=168;
run;
proc univariate data=ramalan normal;
var residual;
run;
proc export data=ramalan
outfile="E:\SUF 6 model 2.xls"
dbms=excel97
replace;
run;

```

**Lampiran 4.** Syntax Pemodelan 1 DSARIMA Data Kandungan  $PM_{10}$  di SUF 7 dengan SAS

```

data polusi;
input y;
datalines;
4.14875
4.20797
4.25490
4.27437
4.26472
4.27479
4.21331
4.33113
4.33185
4.28041
4.27667
...
...
...
4.49346
4.50535
4.51579
;
proc arima data=polusi;
identify var=y(1,24,168);
estimate p=(1,2,7,9,10,11,12,16,17,19,23) q=(4,5,8,20)(24)(168)
noconstant method=cls;
forecast out=ramalan lead=168;
run;
proc univariate data=ramalan normal;
var residual;
run;
proc export data=ramalan
outfile="E:\SUF 7 model 1.xls"
dbms=excel97
replace;
run;

```

**Lampiran 5.** Syntax Pemodelan 2 DSARIMA Data Kandungan  $PM_{10}$  di SUF 7 dengan SAS

```

data polusi;
input y;
datalines;
4.14875
4.20797
4.25490
4.27437
4.26472
4.27479
4.21331
4.33113
4.33185
4.28041
4.27667
...
...
...
4.49346
4.50535
4.51579
;
proc arima data=polusi;
identify var=y(1,24,168);
estimate p=(1,2,4,5,7,8,10,11,12,13,15,16,18,19,20)(24) q=(24)(168)
noconstant method=cls;
forecast out=ramalan lead=168;
run;
proc univariate data=ramalan normal;
var residual;
run;
proc export data=ramalan
outfile="E:\SUF 7 model 2.xls"
dbms=excel97
replace;
run;

```

**Lampiran 6.** Syntax Pemodelan SARIMA Data Kandungan  $PM_{10}$  di SUF 6 jam 10.00 dengan SAS

```
data polusi;
input y;
datalines;
42.270
31.345
52.633
71.860
45.600
45.850
60.657
73.178
47.155
70.233
55.763
...
...
...
79.667
85.138
70.000
;
proc arima data=polusi;
identify var=y(7);
estimate p=(1) q=(1,2)(7)
noconstant method=cls;
forecast out=ramalan lead=7;
run;
proc univariate data=ramalan normal;
var residual;
run;
proc export data=ramalan
outfile="E:\SUF 6 jam 10.xls"
dbms=excel97
replace;
run;
```

**Lampiran 7.** Syntax Pemodelan SARIMA Data Kandungan  $PM_{10}$  di SUF 6 jam 11.00 dengan SAS

```
data polusi;
input y;
datalines;
42.000
32.000
52.875
71.080
50.170
50.360
58.645
69.132
42.305
70.000
53.157
...
...
...
82.808
82.265
68.070
;
proc arima data=polusi;
identify var=y(7);
estimate p=(1) q=(1,2)(7)
noconstant method=cls;
forecast out=ramalan lead=7;
run;
proc univariate data=ramalan normal;
var residual;
run;
proc export data=ramalan
outfile="E:\SUF 6 jam 11.xls"
dbms=excel97
replace;
run;
```

**Lampiran 8.** Syntax Pemodelan SARIMA Data Kandungan  $PM_{10}$  di SUF 6 jam 12.00 dengan SAS

```
data polusi;
input y;
datalines;
42.965
33.125
53.000
71.055
54.212
50.983
57.633
65.720
44.855
69.438
50.133
...
...
...
83.475
81.787
62.852
;
proc arima data=polusi;
identify var=y(7);
estimate p=(1) q=(1,2)(7)
noconstant method=cls;
forecast out=ramalan lead=7;
run;
proc univariate data=ramalan normal;
var residual;
run;
proc export data=ramalan
outfile="E:\SUF 6 jam 12.xls"
dbms=excel97
replace;
run;
```

**Lampiran 9.** Syntax Pemodelan SARIMA Data Kandungan PM<sub>10</sub> di SUF 6 jam 13.00 dengan SAS

```
data polusi;
input y;
datalines;
47.910
36.180
51.035
68.430
56.665
50.513
56.808
59.940
49.000
67.255
41.230
...
...
...
83.500
76.708
57.663
;
proc arima data=polusi;
identify var=y(7);
estimate p=(1) q=(1,2)(7)
noconstant method=cls;
forecast out=ramalan lead=7;
run;
proc univariate data=ramalan normal;
var residual;
run;
proc export data=ramalan
outfile="E:\SUF 6 jam 13.xls"
dbms=excel97
replace;
run;
```



**Lampiran 10.** Syntax Pemodelan SARIMA Data Kandungan  $PM_{10}$  di SUF 7 jam 10.00 dengan SAS

```

data polusi;
input y;
datalines;
42.270
31.345
52.633
71.860
45.600
45.850
60.657
73.178
47.155
70.233
55.763
...
...
...
78.000
71.858
72.868
;
proc arima data=polusi;
identify var=y(7);
estimate p=(1) q=(1,2)(7)
noconstant method=cls;
forecast out=ramalan lead=7;
run;
proc univariate data=ramalan normal;
var residual;
run;
proc export data=ramalan
outfile="E:\SUF 7 jam 10.xls"
dbms=excel97
replace;
run;

```

**Lampiran 11.** Syntax Pemodelan SARIMA Data Kandungan  $PM_{10}$  di SUF 7 jam 11.00 dengan SAS

```
data polusi;
input y;
datalines;
42.000
32.000
52.875
71.080
50.170
50.360
58.645
69.132
42.305
70.000
53.157
...
...
...
77.542
73.892
71.350
;
proc arima data=polusi;
identify var=y(7);
estimate p=(1) q=(1)(7)
noconstant method=cls;
forecast out=ramalan lead=7;
run;
proc univariate data=ramalan normal;
var residual;
run;
proc export data=ramalan
outfile="E:\SUF 7 jam 11.xls"
dbms=excel97
replace;
run;
```

**Lampiran 12.** Syntax Pemodelan SARIMA Data Kandungan  $PM_{10}$  di SUF 7 jam 12.00 dengan SAS

```
data polusi;
input y;
datalines;
42.965
33.125
53.000
71.055
54.212
50.983
57.633
65.720
44.855
69.438
50.133
...
...
...
77.608
77.333
69.313
;
proc arima data=polusi;
identify var=y(7);
estimate p=(1) q=(1)(7)
noconstant method=cls;
forecast out=ramalan lead=7;
run;
proc univariate data=ramalan normal;
var residual;
run;
proc export data=ramalan
outfile="E:\SUF 7 jam 12.xls"
dbms=excel97
replace;
run;
```

**Lampiran 13.** Syntax Pemodelan SARIMA Data Kandungan  $PM_{10}$  di SUF 7 jam 13.00 dengan SAS

```
data polusi;
input y;
datalines;
47.910
36.180
51.035
68.430
56.665
50.513
56.808
59.940
49.000
67.255
41.230
...
...
...
80.167
79.958
64.005
;
proc arima data=polusi;
identify var=y(7);
estimate p=(1) q=(1)(7)
noconstant method=cls;
forecast out=ramalan lead=7;
run;
proc univariate data=ramalan normal;
var residual;
run;
proc export data=ramalan
outfile="E:\SUF 7 jam 13.xls"
dbms=excel97
replace;
run;
```

# Lampiran 14. Output SAS Pemodelan 1 DSARIMA Data Kandungan PM<sub>10</sub> di SUF 6

Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Pr >  t	Lag					
MA1,1	0.79937	0.0087592	91.26	<.0001	24					
MA2,1	0.84080	0.0065206	128.95	<.0001	168					
AR1,1	0.47654	0.01122	42.46	<.0001	1					
AR1,2	-0.06204	0.01137	-5.45	<.0001	2					
AR1,3	-0.02686	0.01004	-2.68	0.0075	4					
AR1,4	-0.05057	0.01079	-4.69	<.0001	7					
AR1,5	-0.28195	0.01249	-22.57	<.0001	8					
AR1,6	0.12752	0.01273	10.02	<.0001	9					
AR1,7	-0.11419	0.01171	-9.75	<.0001	10					
AR1,8	-0.05869	0.01005	-5.84	<.0001	12					
AR1,9	-0.15390	0.01173	-13.13	<.0001	16					
AR1,10	0.07087	0.01253	5.66	<.0001	17					
AR1,11	-0.07143	0.01127	-6.34	<.0001	18					
AR2,1	-0.05240	0.01430	-3.67	0.0002	24					
Variance Estimate			0.002704							
Std Error Estimate			0.052002							
AIC			-24042.4							
SBC			-23944.9							
Number of Residuals			7823							
* AIC and SBC do not include log determinant.										
Autocorrelation Check of Residuals										
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----						
6	.	0	.	0.001	-0.014	0.022	0.003	-0.011	-0.009	
12	.	0	.	-0.006	0.001	-0.004	-0.008	0.015	-0.002	
18	15.88	4	0.0032	-0.012	-0.014	-0.020	0.001	-0.002	0.008	
24	23.27	10	0.0098	-0.016	-0.018	-0.010	-0.016	0.002	-0.001	
30	29.60	16	0.0202	-0.008	0.003	0.005	-0.026	-0.000	-0.004	
36	52.08	22	0.0003	-0.020	-0.022	-0.000	-0.042	-0.000	-0.015	
42	70.11	28	<.0001	-0.013	0.019	-0.000	-0.020	-0.011	-0.035	
48	80.64	34	<.0001	-0.018	-0.013	-0.013	-0.009	0.005	-0.024	
Model for variable y										
Period(s) of Differencing						1,24,168				
No mean term in this model.										
Autoregressive Factors										
Factor 1: 1 - 0.47654 B**(1) + 0.06204 B**(2) + 0.02686 B**(4) + 0.05057 B**(7) + 0.28195 B**(8) - 0.12752 B**(9) + 0.11419 B**(10) + 0.05869 B**(12) + 0.1539 B**(16) - 0.07087 B**(17) + 0.07143 B**(18)										
Factor 2: 1 + 0.0524 B**(24)										
Moving Average Factors										
Factor 1: 1 - 0.79937 B**(24)										
Factor 2: 1 - 0.8408 B**(168)										
Tests for Normality										
Test	--Statistic--		-----p Value-----							
Kolmogorov-Smirnov	D	0.069206	Pr > D	<.0100						
Cramer-von Mises	W-Sq	15.53856	Pr > W-Sq	<.0050						
Anderson-Darling	A-Sq	89.14056	Pr > A-Sq	<.0050						

### Lampiran 15. Output SAS Pemodelan 2 DSARIMA Data Kandungan $PM_{10}$ di SUF 6

Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Pr >  t	Approx Lag
MA1,1	0.79794	0.0088056	90.62	<.0001	24
MA2,1	0.84104	0.0065233	128.93	<.0001	168
AR1,1	0.48027	0.01127	42.60	<.0001	1
AR1,2	-0.07708	0.01249	-6.17	<.0001	2
AR1,3	0.03396	0.01235	2.75	0.0060	3
AR1,4	-0.03939	0.01115	-3.53	0.0004	4
AR1,5	-0.05039	0.01079	-4.67	<.0001	7
AR1,6	-0.28158	0.01249	-22.54	<.0001	8
AR1,7	0.12813	0.01275	10.05	<.0001	9
AR1,8	-0.12592	0.01273	-9.89	<.0001	10
AR1,9	0.03229	0.01240	2.60	0.0092	11
AR1,10	-0.07132	0.01115	-6.40	<.0001	12
AR1,11	-0.15196	0.01173	-12.95	<.0001	16
AR1,12	0.06971	0.01253	5.56	<.0001	17
AR1,13	-0.06980	0.01128	-6.19	<.0001	18
AR2,1	-0.05352	0.01432	-3.74	0.0002	24
Variance Estimate			0.002701		
Std Error Estimate			0.05197		
AIC			-24050		
SBC			-23938.6		
Number of Residuals			7823		
* AIC and SBC do not include log determinant.					

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	.	0	.	-0.002	-0.001	-0.005	0.001	-0.009	-0.009
12	.	0	.	-0.005	0.002	-0.004	0.001	-0.003	-0.003
18	6.97	2	0.0307	-0.008	-0.013	-0.019	0.001	-0.001	0.003
24	12.72	8	0.1219	-0.006	-0.019	-0.009	-0.015	0.003	-0.001
30	18.42	14	0.1882	-0.006	0.003	0.004	-0.025	-0.001	-0.004
36	40.10	20	0.0049	-0.018	-0.023	-0.000	-0.041	-0.002	-0.015
42	57.36	26	0.0004	-0.011	0.019	0.001	-0.019	-0.011	-0.035
48	67.09	32	0.0003	-0.016	-0.014	-0.010	-0.008	0.004	-0.025

Model for variable y

Period(s) of Differencing 1,24,168

The ARIMA Procedure

No mean term in this model.

Autoregressive Factors

Factor 1: 1 - 0.48027 B\*\*(1) + 0.07708 B\*\*(2) - 0.03396 B\*\*(3) + 0.03939 B\*\*(4) + 0.05039 B\*\*(7) + 0.28158 B\*\*(8) - 0.12813 B\*\*(9) + 0.12592 B\*\*(10) - 0.03229 B\*\*(11) + 0.07132 B\*\*(12) + 0.15196 B\*\*(16) - 0.06971 B\*\*(17) + 0.0698 B\*\*(18)

Factor 2: 1 + 0.05352 B\*\*(24)

Moving Average Factors

Factor 1: 1 - 0.79794 B\*\*(24)

Factor 2: 1 - 0.84104 B\*\*(168)

Tests for Normality

Test	--Statistic--	-----p Value-----
Kolmogorov-Smirnov	D 0.071129	Pr > D <0.0100
Cramer-von Mises	W-Sq 15.70287	Pr > W-Sq <0.0050
Anderson-Darling	A-Sq 90.03293	Pr > A-Sq <0.0050

# Lampiran 16. Output SAS Pemodelan 1 DSARIMA Data Kandungan PM<sub>10</sub> di SUF 7

Conditional Least Squares Estimation									
Parameter	Estimate	Standard Error	t Value	Pr >  t	Lag				
MA1,1	0.03241	0.01139	2.85	0.0044	4				
MA1,2	0.03989	0.01109	3.60	0.0003	5				
MA1,3	0.20605	0.01164	17.70	<.0001	8				
MA1,4	0.02212	0.01137	1.95	0.0518	20				
MA2,1	0.81255	0.0069959	116.15	<.0001	24				
MA3,1	0.85162	0.0062565	136.12	<.0001	168				
AR1,1	0.23265	0.01128	20.63	<.0001	1				
AR1,2	0.07174	0.01131	6.34	<.0001	2				
AR1,3	-0.09313	0.01124	-8.29	<.0001	7				
AR1,4	-0.04195	0.01143	-3.67	0.0002	9				
AR1,5	-0.06985	0.01161	-6.02	<.0001	10				
AR1,6	-0.03478	0.01157	-3.00	0.0027	11				
AR1,7	-0.04996	0.01158	-4.32	<.0001	12				
AR1,8	-0.05492	0.01153	-4.76	<.0001	16				
AR1,9	-0.02043	0.01136	-1.80	0.0721	17				
AR1,10	-0.03502	0.01117	-3.13	0.0017	19				
AR1,11	0.02168	0.01097	1.98	0.0482	23				
Variance Estimate			0.002612						
Std Error Estimate			0.051108						
AIC			-24310.7						
SBC			-24192.3						
Number of Residuals			7823						
* AIC and SBC do not include log determinant.									
Autocorrelation Check of Residuals									
To	Chi-Square	DF	Pr >	-----Autocorrelations-----					
Lag			ChiSq						
6	.	0	.	-0.001	-0.004	-0.001	-0.000	0.005	-0.021
12	.	0	.	-0.002	0.002	0.002	0.002	0.001	0.006
18	13.51	1	0.0002	-0.018	-0.017	-0.022	0.001	0.002	-0.012
24	18.02	7	0.0119	0.000	0.004	-0.012	-0.007	-0.008	-0.017
30	23.99	13	0.0312	0.006	0.022	0.004	-0.006	-0.013	-0.003
36	43.21	19	0.0012	-0.010	-0.038	-0.019	-0.018	-0.006	-0.012
42	54.85	25	0.0005	-0.003	-0.003	-0.005	-0.017	-0.004	-0.034
48	62.95	31	0.0006	-0.018	-0.007	-0.012	0.008	0.013	-0.016
Model for variable y									
Period(s) of Differencing							1,24,168		
No mean term in this model.									
Autoregressive Factors									
Factor 1:							1 - 0.23265 B**(1) - 0.07174 B**(2) + 0.09313 B**(7) + 0.04195 B**(9) + 0.06985 B**(10) + 0.03478 B**(11) + 0.04996 B**(12) + 0.05492 B**(16) + 0.02043 B**(17) + 0.03502 B**(19) - 0.02168 B**(23)		
Moving Average Factors									
Factor 1:							1 - 0.03241 B**(4) - 0.03989 B**(5) - 0.20605 B**(8) - 0.02212 B**(20)		
Factor 2:							1 - 0.81255 B**(24)		
Factor 3:							1 - 0.85162 B**(168)		
Tests for Normality									
Test	--Statistic--		----p Value-----						
Kolmogorov-Smirnov	D	0.094853	Pr > D	<0.0100					
Cramer-von Mises	W-Sq	31.95262	Pr > W-Sq	<0.0050					
Anderson-Darling	A-Sq	193.2123	Pr > A-Sq	<0.0050					

# **Lampiran 17.** Output SAS Pemodelan 2 DSARIMA Data Kandungan PM<sub>10</sub> di SUF 7

Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Pr >  t	Approx Lag
MA1,1	0.80681	0.0085481	94.38	<.0001	24
MA2,1	0.85276	0.0062571	136.29	<.0001	168
AR1,1	0.23220	0.01106	20.99	<.0001	1
AR1,2	0.06885	0.01134	6.07	<.0001	2
AR1,3	-0.03227	0.01133	-2.85	0.0044	4
AR1,4	-0.02851	0.01129	-2.52	0.0116	5
AR1,5	-0.08930	0.01125	-7.94	<.0001	7
AR1,6	-0.20324	0.01143	-17.78	<.0001	8
AR1,7	-0.05326	0.01157	-4.60	<.0001	10
AR1,8	-0.03581	0.01161	-3.08	0.0021	11
AR1,9	-0.05851	0.01183	-4.95	<.0001	12
AR1,10	-0.03235	0.01133	-2.85	0.0043	13
AR1,11	-0.04234	0.01129	-3.75	0.0002	15
AR1,12	-0.09680	0.01156	-8.37	<.0001	16
AR1,13	-0.03080	0.01137	-2.71	0.0068	18
AR1,14	-0.04107	0.01153	-3.56	0.0004	19
AR1,15	-0.02949	0.01132	-2.60	0.0092	20
AR2,1	-0.04282	0.01410	-3.04	0.0024	24
Variance Estimate		0.002609			
Std Error Estimate		0.05108			
AIC		-24318.2			
SBC		-24192.8			
Number of Residuals		7823			

\* AIC and SBC do not include log determinant.

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----				
6	.	0	.	-0.001	-0.002	0.000	0.001	-0.009
12	.	0	.	-0.000	-0.000	0.003	-0.001	-0.002
18	.	0	.	-0.002	-0.015	0.002	0.003	-0.020
24	10.54	6	0.1037	-0.002	-0.006	-0.020	-0.012	-0.001
30	17.94	12	0.1176	-0.004	0.012	-0.009	-0.020	-0.016
36	34.91	18	0.0097	-0.009	-0.037	-0.018	-0.016	-0.011
42	45.09	24	0.0057	0.000	0.001	-0.002	-0.013	-0.002
48	54.73	30	0.0038	-0.017	-0.006	-0.012	0.007	-0.023

Model for variable y

Period(s) of Differencing 1,24,168

No mean term in this model.

Autoregressive Factors

Factor 1: 1 - 0.2322 B\*\*(1) - 0.06885 B\*\*(2) + 0.03227 B\*\*(4) + 0.02851 B\*\*(5) + 0.0893 B\*\*(7) + 0.20324 B\*\*(8) + 0.05326 B\*\*(10) + 0.03581 B\*\*(11) + 0.05851 B\*\*(12) + 0.03235 B\*\*(13) + 0.04234 B\*\*(15) + 0.0968 B\*\*(16) + 0.0308 B\*\*(18) + 0.04107 B\*\*(19) + 0.02949 B\*\*(20)

Factor 2: 1 + 0.04282 B\*\*(24)

Moving Average Factors

Factor 1: 1 - 0.80681 B\*\*(24)

Factor 2: 1 - 0.85276 B\*\*(168)

Tests for Normality

Test	--Statistic--	-----p Value-----
Kolmogorov-Smirnov	D 0.096155	Pr > D <0.0100
Cramer-von Mises	W-Sq 31.61997	Pr > W-Sq <0.0050
Anderson-Darling	A-Sq 191.7079	Pr > A-Sq <0.0050



**Lampiran 18.** Output SAS Pemodelan SARIMA Data Kandungan PM<sub>10</sub> pukul 10.00 di SUF 6

Conditional Least Squares Estimation									
Parameter	Estimate		Standard Error	t Value	Pr >  t	Lag			
MA1,1	0.36746		0.09900	3.71	0.0002	1			
MA1,2	0.19534		0.07744	2.52	0.0121	2			
MA2,1	0.89533		0.02671	33.51	<.0001	7			
AR1,1	0.85115		0.07772	10.95	<.0001	1			
			Variance Estimate	406.3245					
			Std Error Estimate	20.15749					
			AIC	2896.3					
			SBC	2911.46					
			Number of Residuals	327					
* AIC and SBC do not include log determinant.									
Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	3.37	2	0.1854	0.009	0.025	-0.026	-0.036	-0.074	0.043
12	9.77	8	0.2817	-0.015	0.040	0.050	0.110	-0.040	-0.029
18	13.95	14	0.4535	0.068	-0.039	-0.032	-0.057	-0.035	-0.022
24	15.56	20	0.7433	0.031	0.005	0.022	0.041	0.032	0.019
30	17.71	26	0.8862	0.016	-0.024	-0.040	-0.023	-0.034	-0.042
36	29.54	32	0.5915	-0.072	0.105	-0.089	0.079	0.039	0.021
42	38.06	38	0.4667	-0.115	0.054	-0.025	-0.076	-0.015	-0.009
48	42.39	44	0.5409	0.016	0.043	0.072	0.013	0.060	0.015
Model for variable y									
Period(s) of Differencing				7					
No mean term in this model.									
Autoregressive Factors									
Factor 1: 1 - 0.85115 B**(1)									
Moving Average Factors									
Factor 1: 1 - 0.36746 B**(1) - 0.19534 B**(2)									
Factor 2: 1 - 0.89533 B**(7)									
Tests for Normality									
Test	--Statistic--			-----p Value-----					
Shapiro-Wilk	W	0.986947	Pr < W	0.0048					
Kolmogorov-Smirnov	D	0.050223	Pr > D	0.0437					
Cramer-von Mises	W-Sq	0.166489	Pr > W-Sq	0.0156					
Anderson-Darling	A-Sq	1.093879	Pr > A-Sq	0.0075					

**Lampiran 19.** Output SAS Pemodelan SARIMA Data Kandungan PM<sub>10</sub> pukul 11.00 di SUF 6

Conditional Least Squares Estimation									
Parameter	Estimate		Standard Error	t Value	Pr >  t	Lag			
MA1,1	0.40483		0.09460	4.28	<.0001	1			
MA1,2	0.20682		0.07530	2.75	0.0064	2			
MA2,1	0.90169		0.02628	34.31	<.0001	7			
AR1,1	0.86968		0.07283	11.94	<.0001	1			
			Variance Estimate	378.8576					
			Std Error Estimate	19.46426					
			AIC	2873.413					
			SBC	2888.572					
			Number of Residuals	327					
* AIC and SBC do not include log determinant.									
Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	4.72	2	0.0942	0.013	0.035	-0.031	-0.048	-0.086	0.046
12	11.72	8	0.1640	-0.026	0.056	0.082	0.084	-0.039	-0.037
18	15.90	14	0.3194	0.066	-0.040	-0.024	-0.040	-0.056	-0.029
24	17.65	20	0.6104	0.034	0.010	0.028	0.041	0.033	0.010
30	19.88	26	0.7970	0.016	0.003	-0.042	-0.029	-0.043	-0.039
36	32.65	32	0.4346	-0.090	0.102	-0.074	0.089	0.038	0.036
42	40.59	38	0.3570	-0.105	0.040	-0.016	-0.091	-0.013	-0.001
48	45.73	44	0.4001	0.022	0.053	0.073	0.007	0.067	0.017
Model for variable y									
Period(s) of Differencing 7									
No mean term in this model.									
Autoregressive Factors									
Factor 1: 1 - 0.86968 B**(1)									
Moving Average Factors									
Factor 1: 1 - 0.40483 B**(1) - 0.20682 B**(2)									
Factor 2: 1 - 0.90169 B**(7)									
Tests for Normality									
Test	--Statistic--			-----p Value-----					
Shapiro-Wilk	W	0.982707	Pr < W	0.0006					
Kolmogorov-Smirnov	D	0.053587	Pr > D	0.0220					
Cramer-von Mises	W-Sq	0.263762	Pr > W-Sq	<0.0050					
Anderson-Darling	A-Sq	1.592883	Pr > A-Sq	<0.0050					

**Lampiran 20.** Output SAS Pemodelan SARIMA Data Kandungan PM<sub>10</sub> pukul 12.00 di SUF 6

Conditional Least Squares Estimation									
Parameter	Estimate		Standard Error	t Value	Approx Pr >  t	Lag			
MA1,1	0.44837		0.08937	5.02	<.0001	1			
MA1,2	0.22613		0.07258	3.12	0.0020	2			
MA2,1	0.90195		0.02648	34.06	<.0001	7			
AR1,1	0.89193		0.06679	13.35	<.0001	1			
Variance Estimate				339.1766					
Std Error Estimate				18.41675					
AIC				2837.234					
SBC				2852.393					
Number of Residuals				327					
* AIC and SBC do not include log determinant.									
Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	4.71	2	0.0948	0.012	0.031	-0.026	-0.036	-0.093	0.049
12	11.74	8	0.1633	-0.031	0.063	0.097	0.060	-0.047	-0.025
18	16.29	14	0.2960	0.055	-0.037	-0.042	-0.036	-0.075	-0.014
24	17.92	20	0.5929	0.031	0.019	0.040	0.026	0.031	-0.010
30	20.25	26	0.7797	0.012	0.027	-0.040	-0.032	-0.048	-0.025
36	34.56	32	0.3464	-0.113	0.114	-0.062	0.090	0.027	0.029
42	41.27	38	0.3295	-0.086	0.045	-0.021	-0.084	-0.022	0.026
48	45.94	44	0.3917	0.011	0.056	0.063	0.013	0.058	0.038
Model for variable y									
Period(s) of Differencing				7					
No mean term in this model.									
Autoregressive Factors									
Factor 1: 1 - 0.89193 B**(1)									
Moving Average Factors									
Factor 1: 1 - 0.44837 B**(1) - 0.22613 B**(2)									
Factor 2: 1 - 0.90195 B**(7)									
Tests for Normality									
Test	--Statistic--			-----p Value-----					
Shapiro-Wilk	W	0.978684	Pr < W	<0.0001					
Kolmogorov-Smirnov	D	0.062701	Pr > D	<0.0100					
Cramer-von Mises	W-Sq	0.346269	Pr > W-Sq	<0.0050					
Anderson-Darling	A-Sq	2.046048	Pr > A-Sq	<0.0050					

**Lampiran 21.** Output SAS Pemodelan SARIMA Data Kandungan PM<sub>10</sub> pukul 13.00 di SUF 6

Conditional Least Squares Estimation									
Parameter	Estimate		Standard Error	t Value	Approx Pr >  t	Lag			
MA1,1	0.47429		0.08691	5.46	<.0001	1			
MA1,2	0.23664		0.07110	3.33	0.0010	2			
MA2,1	0.90903		0.02570	35.37	<.0001	7			
AR1,1	0.90370		0.06394	14.13	<.0001	1			
Variance Estimate				304.261					
Std Error Estimate				17.44308					
AIC				2801.71					
SBC				2816.87					
Number of Residuals				327					
* AIC and SBC do not include log determinant.									
Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	5.22	2	0.0735	0.011	0.030	-0.020	-0.026	-0.109	0.041
12	11.74	8	0.1634	-0.021	0.056	0.115	0.030	-0.019	-0.033
18	15.35	14	0.3549	0.039	-0.043	-0.049	-0.031	-0.061	0.004
24	17.06	20	0.6493	0.040	0.014	0.041	0.022	0.029	-0.011
30	20.30	26	0.7770	0.009	0.029	-0.052	-0.014	-0.069	-0.019
36	31.63	32	0.4853	-0.104	0.094	-0.054	0.089	0.019	0.015
42	37.63	38	0.4863	-0.065	0.069	-0.025	-0.077	-0.006	0.022
48	41.84	44	0.5648	0.018	0.050	0.056	0.031	0.043	0.048
Model for variable y									
Period(s) of Differencing 7									
No mean term in this model.									
Autoregressive Factors									
Factor 1: 1 - 0.9037 B**(1)									
Moving Average Factors									
Factor 1: 1 - 0.47429 B**(1) - 0.23664 B**(2)									
Factor 2: 1 - 0.90903 B**(7)									
Tests for Normality									
Test	--Statistic--			-----p Value-----					
Shapiro-Wilk	W	0.975863	Pr < W	<0.0001					
Kolmogorov-Smirnov	D	0.06245	Pr > D	<0.0100					
Cramer-von Mises	W-Sq	0.36917	Pr > W-Sq	<0.0050					
Anderson-Darling	A-Sq	2.223789	Pr > A-Sq	<0.0050					

**Lampiran 22.** Output SAS Pemodelan SARIMA Data Kandungan PM<sub>10</sub> pukul 10.00 di SUF 7

Conditional Least Squares Estimation									
Parameter	Estimate		Standard Error	t Value	Approx Pr >  t	Lag			
MA1,1	0.25191		0.09873	2.55	0.0112	1			
MA2,1	0.83904		0.03112	26.96	<.0001	7			
AR1,1	0.70345		0.07329	9.60	<.0001	1			
Variance Estimate				449.4196					
Std Error Estimate				21.19952					
AIC				2928.274					
SBC				2939.644					
Number of Residuals				327					
* AIC and SBC do not include log determinant.									
Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	1.75	3	0.6255	0.002	-0.005	0.000	-0.028	-0.032	0.058
12	10.95	9	0.2792	-0.005	-0.004	0.094	0.126	-0.043	0.024
18	12.29	15	0.6570	0.028	-0.044	-0.033	-0.005	0.003	0.008
24	22.79	21	0.3554	0.034	0.093	0.031	0.138	0.009	0.000
30	27.00	27	0.4638	0.038	0.096	0.003	-0.033	0.001	-0.001
36	36.47	33	0.3103	0.041	0.003	-0.108	-0.015	0.089	0.065
42	40.47	39	0.4053	-0.066	0.064	-0.033	-0.020	0.014	0.023
48	52.18	45	0.2151	0.019	0.032	-0.011	0.025	0.077	0.150
Model for variable y									
Period(s) of Differencing				7					
No mean term in this model.									
Autoregressive Factors									
Factor 1: 1 - 0.70345 B**(1)									
Moving Average Factors									
Factor 1: 1 - 0.25191 B**(1)									
Factor 2: 1 - 0.83904 B**(7)									
Tests for Normality									
Test	--Statistic--			-----p Value-----					
Shapiro-Wilk	W	0.987835	Pr < W	0.0077					
Kolmogorov-Smirnov	D	0.051114	Pr > D	0.0370					
Cramer-von Mises	W-Sq	0.211249	Pr > W-Sq	<0.0050					
Anderson-Darling	A-Sq	1.202849	Pr > A-Sq	<0.0050					

**Lampiran 23.** Output SAS Pemodelan SARIMA Data Kandungan PM<sub>10</sub> pukul 11.00 di SUF 7

Conditional Least Squares Estimation									
Parameter	Estimate		Standard Error	t Value	Approx Pr >  t	Lag			
MA1,1	0.23249		0.09755	2.38	0.0177	1			
MA2,1	0.83693		0.03120	26.82	<.0001	7			
AR1,1	0.69912		0.07243	9.65	<.0001	1			
Variance Estimate				404.8528					
Std Error Estimate				20.12095					
AIC				2894.124					
SBC				2905.494					
Number of Residuals				327					
* AIC and SBC do not include log determinant.									
Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	3.79	3	0.2845	-0.004	0.031	-0.050	-0.006	-0.052	0.072
12	14.22	9	0.1149	-0.011	0.008	0.097	0.131	-0.050	0.040
18	15.29	15	0.4311	-0.000	-0.024	-0.047	0.017	-0.004	0.003
24	26.02	21	0.2056	0.028	0.120	0.023	0.122	0.005	-0.002
30	30.26	27	0.3026	0.029	0.102	0.001	-0.023	-0.005	-0.012
36	36.98	33	0.2901	0.026	-0.003	-0.089	-0.002	0.062	0.076
42	41.59	39	0.3586	-0.074	0.058	-0.031	-0.024	0.025	0.036
48	53.42	45	0.1823	0.030	0.011	0.003	0.017	0.072	0.156
Model for variable y									
Period(s) of Differencing 7									
No mean term in this model.									
Autoregressive Factors									
Factor 1: 1 - 0.69912 B**(1)									
Moving Average Factors									
Factor 1: 1 - 0.23249 B**(1)									
Factor 2: 1 - 0.83693 B**(7)									
Tests for Normality									
Test	--Statistic--			-----p Value-----					
Shapiro-Wilk	W	0.992762	Pr < W	0.1148					
Kolmogorov-Smirnov	D	0.046563	Pr > D	0.0837					
Cramer-von Mises	W-Sq	0.11196	Pr > W-Sq	0.0815					
Anderson-Darling	A-Sq	0.712478	Pr > A-Sq	0.0656					

**Lampiran 24.** Output SAS Pemodelan SARIMA Data Kandungan PM<sub>10</sub> pukul 12.00 di SUF 7

Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag
MA1,1	0.24340	0.10037	2.43	0.0159	1
MA2,1	0.83675	0.03118	26.83	<.0001	7
AR1,1	0.69214	0.07534	9.19	<.0001	1
Variance Estimate			377.9662		
Std Error Estimate			19.44135		
AIC			2871.653		
SBC			2883.023		
Number of Residuals			327		
* AIC and SBC do not include log determinant.					

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	7.19	3	0.0660	-0.008	0.053	-0.078	0.008	-0.068	0.089
12	16.98	9	0.0490	-0.030	0.037	0.087	0.116	-0.047	0.056
18	18.09	15	0.2582	-0.014	-0.020	-0.042	0.025	0.001	0.013
24	26.24	21	0.1975	0.006	0.110	0.038	0.093	0.026	-0.016
30	30.54	27	0.2902	0.031	0.101	-0.005	-0.023	-0.018	-0.003
36	36.31	33	0.3170	0.008	0.008	-0.076	-0.001	0.040	0.090
42	42.47	39	0.3240	-0.074	0.060	-0.050	-0.012	0.018	0.067
48	54.36	45	0.1599	0.020	-0.013	0.021	0.023	0.049	0.164

Model for variable y

Period(s) of Differencing 7

No mean term in this model.

Autoregressive Factors

Factor 1: 1 - 0.69214 B\*\*(1)

Moving Average Factors

Factor 1: 1 - 0.2434 B\*\*(1)

Factor 2: 1 - 0.83675 B\*\*(7)

Tests for Normality


Test	--Statistic--		-----p Value-----	
Shapiro-Wilk	W	0.993668	Pr < W	0.1878
Kolmogorov-Smirnov	D	0.043167	Pr > D	0.1418
Cramer-von Mises	W-Sq	0.124872	Pr > W-Sq	0.0521
Anderson-Darling	A-Sq	0.710027	Pr > A-Sq	0.0667

**Lampiran 25.** Output SAS Pemodelan SARIMA Data Kandungan PM<sub>10</sub> pukul 13.00 di SUF 7


Conditional Least Squares Estimation									
Parameter	Estimate		Standard Error	t Value	Pr >  t	Lag			
MA1,1	0.23090		0.10743	2.15	0.0324	1			
MA2,1	0.83483		0.03136	26.62	<.0001	7			
AR1,1	0.65938		0.08358	7.89	<.0001	1			
Variance Estimate				366.5389					
Std Error Estimate				19.14521					
AIC				2861.614					
SBC				2872.984					
Number of Residuals				327					
* AIC and SBC do not include log determinant.									
Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	5.57	3	0.1346	-0.008	0.055	-0.087	0.016	-0.044	0.062
12	13.84	9	0.1283	-0.020	0.051	0.065	0.115	-0.035	0.050
18	15.73	15	0.4001	-0.027	-0.015	-0.053	0.009	0.039	0.013
24	20.45	21	0.4932	0.024	0.079	0.056	0.051	0.028	0.005
30	24.14	27	0.6225	0.025	0.086	-0.005	-0.027	-0.026	-0.030
36	27.95	33	0.7169	0.043	-0.016	-0.040	-0.012	0.004	0.081
42	31.81	39	0.7863	-0.047	0.032	-0.064	0.005	0.029	0.046
48	44.09	45	0.5104	0.032	-0.053	0.060	0.026	0.021	0.153
Model for variable y									
Period(s) of Differencing 7									
No mean term in this model.									
Autoregressive Factors									
Factor 1: 1 - 0.65938 B**(1)									
Moving Average Factors									
Factor 1: 1 - 0.2309 B**(1)									
Factor 2: 1 - 0.83483 B**(7)									
Tests for Normality									
Test	--Statistic---			-----p Value-----					
Shapiro-Wilk	W	0.991418	Pr < W	0.0545					
Kolmogorov-Smirnov	D	0.049556	Pr > D	0.0488					
Cramer-von Mises	W-Sq	0.127553	Pr > W-Sq	0.0480					
Anderson-Darling	A-Sq	0.730913	Pr > A-Sq	0.0580					




**Lampiran 26.** *Box Cox* Data Kandungan PM10 di SUF 6 Sebelum Ditransformasi




**Lampiran 27.** *Box Cox* Data Kandungan PM10 di SUF 7 Sebelum Ditransformasi




**Lampiran 28.** *Box Cox* Data Kandungan PM10 di SUF 6 Setelah Ditransformasi




**Lampiran 29.** *Box Cox* Data Kandungan PM10 di SUF 7 Setelah Ditransformasi




**Lampiran 30. Summary Table Residual Model 1 Kandungan PM10 di  
SUF 6**




**Lampiran 31. Summary Table Residual Model 2 Kandungan PM10 di  
SUF 6**




### Lampiran 32. Summary Table Residual Model 1 Kandungan PM10 di SUF 7




### Lampiran 33. Summary Table Residual Model 2 Kandungan PM10 di SUF 7




**Lampiran 34.** *Summary Table* Residual Model ARIMA Kandungan PM10 Pukul 10.00 di SUF 6




**Lampiran 35.** *Summary Table* Residual Model ARIMA Kandungan PM10 Pukul 11.00 di SUF 6




**Lampiran 36. Summary Table Residual Model ARIMA Kandungan PM10 Pukul 12.00 di SUF 6**




**Lampiran 37. Summary Table Residual Model ARIMA Kandungan PM10 Pukul 13.00 di SUF 6**




**Lampiran 38. Summary Table** Residual Model ARIMA Kandungan PM10 Pukul 10.00 di SUF 7




**Lampiran 39. Summary Table** Residual Model ARIMA Kandungan PM10 Pukul 11.00 di SUF 7



**Lampiran 40. Summary Table Residual Model ARIMA Kandungan PM10 Pukul 12.00 di SUF 7**




**Lampiran 41. Summary Table Residual Model ARIMA Kandungan PM10 Pukul 13.00 di SUF 7**







**Lampiran 42.** Plot *Time Series* Data Aktual dan Ramalan *In Sample* dan *Out Sample* Pukul 10.00 di SUF 6




**Lampiran 43.** Plot *Time Series* Data Aktual dan Ramalan *In Sample* dan *Out Sample* Pukul 11.00 di SUF 6




**Lampiran 44.** Plot *Time Series* Data Aktual dan Ramalan *In Sample* dan *Out Sample* Pukul 12.00 di SUF 6




**Lampiran 45.** Plot *Time Series* Data Aktual dan Ramalan *In Sample* dan *Out Sample* Pukul 13.00 di SUF 6




**Lampiran 46.** Plot Time Series Data Aktual dan Ramalan *In Sample* dan *Out Sample* Pukul 10.00 di SUF 7




**Lampiran 47.** Plot Time Series Data Aktual dan Ramalan *In Sample* dan *Out Sample* Pukul 11.00 di SUF 7



**Lampiran 48.** Plot *Time Series* Data Aktual dan Ramalan *In Sample* dan *Out Sample* Pukul 12.00 di SUF 7



**Lampiran 49.** Plot *Time Series* Data Aktual dan Ramalan *In Sample* dan *Out Sample* Pukul 13.00 di SUF 7



## BIODATA PENULIS



Penulis, Bernadeta Chrisdayanti lahir di Magetan pada tanggal 21 Desember 1992. Penulis adalah anak kedua dari dua bersaudara. Jenjang pendidikan yang telah ditempuh penulis antara lain TK Kartika V-7 Magetan pada tahun 1997-1999. Menempuh Sekolah Dasar di SDN Sukowinangun 3 Magetan (1999-2005), SMP Negeri 1 Magetan (2005-2008), dan SMA Negeri 1 Magetan (2008-2011). Setelah lulus SMA penulis melanjutkan studi di

Jurusan Statistika ITS melalui jalur undangan dan tercatat sebagai mahasiswa Statistika FMIPA ITS dengan NRP 1311100005 pada tahun 2011. Penulis pernah aktif sebagai panitia dan pengurus di Persekutuan Mahasiswa Kristen (PMK) ITS sejak April 2012 hingga April 2015. Selain itu, penulis juga pernah aktif dalam kepanitian dan kegiatan yang diadakan oleh Jurusan Statistika ITS, seperti Statistics Competition (Station) dan Data Analysis Competition (DAC). Pelatihan kepemimpinan yang diikuti oleh penulis selama kuliah adalah Pelatihan LKMM Pra-TD dan LKMM TD, serta Pelatihan Kepemimpinan Kristen se-Surabaya. Di tahun terakhir kuliah, penulis menjadi Asisten Dosen pada mata kuliah *Experiment Design* dan Analisis Data I. Selain menempuh kuliah, penulis juga mengajar Matematika di Pusat Pengembangan Anak (PPA) – IO 856 GBI Nazareth Surabaya sejak Oktober 2012 hingga lulus kuliah. Apabila pembaca ingin berdiskusi mengenai tugas akhir ini atau materi yang berhubungan, penulis dapat dihubungi melalui email: [bernadeta.chrisdayanti@yahoo.com](mailto:bernadeta.chrisdayanti@yahoo.com) / [bernadeta2112@gmail.com](mailto:bernadeta2112@gmail.com).  
***“Jagalah hatimu dengan segala kewaspadaan, karena dari situlah terpancar kehidupan” (Amsal 4:23)***